

Monitoramento Colaborativo em Tempo Real de Áreas Alagadas com Triagem Automatizada por IA

Real-Time Collaborative Monitoring of Flooded Areas with AI-Based Automated Triage

Rayane Melo Castilhos¹
Frederico Schardong²

Resumo

Este trabalho apresenta o desenvolvimento de um aplicativo móvel para o monitoramento colaborativo em tempo real de áreas alagadas, com apoio de triagem automatizada por inteligência artificial. A proposta busca permitir que a comunidade registre pontos de alagamento em um mapa interativo, informando localização, nível de severidade e imagens do local. Os registros enviados pelos usuários são analisados em um painel administrativo, no qual podem ser aprovados ou rejeitados antes de serem disponibilizados à comunidade. Além disso, a solução utiliza inteligência artificial como recurso de apoio à análise das imagens recebidas, auxiliando na identificação de indícios visuais de alagamento e na sinalização de registros inconsistentes ou inadequados. Para isso, foram avaliados modelos de IA abertos executados localmente, buscando reduzir custos operacionais e a dependência de provedores externos. Espera-se que a ferramenta contribua para melhorar o fluxo de informações durante períodos de chuva intensa, apoiar a tomada de decisão da população e fortalecer o monitoramento colaborativo de áreas afetadas.

Palavras-chave: Áreas alagadas. Monitoramento colaborativo. Aplicativo móvel. Inteligência artificial. Ciência Cidadã.

¹Acadêmica do curso Tecnólogo em Análise e Desenvolvimento de Sistemas do Instituto Federal do Rio Grande do Sul - *Campus Rolante*. raymeloc@gmail.com

²Orientador. Doutor. Docente do Instituto Federal do Rio Grande do Sul - *Campus Rolante*. frederico.schardong@rolante.ifrs.edu.br

Abstract

This work presents the development of a mobile application for real-time collaborative monitoring of flooded areas, supported by automated artificial intelligence triage. The proposal aims to enable the community to report flooding points on an interactive map, providing location, severity level, and images of the area. The reports submitted by users are analyzed in an administrative dashboard, where they can be approved or rejected before being made available to the community. In addition, the solution uses artificial intelligence as a support tool for analyzing the received images, helping to identify visual evidence of flooding and to flag inconsistent or inappropriate reports. To this end, open AI models executed locally were evaluated, aiming to reduce operational costs and dependence on external providers. The tool is expected to contribute to improving the flow of information during periods of heavy rainfall, supporting decision-making by the population, and strengthening collaborative monitoring of affected areas.

Keywords: Flooded areas. Collaborative monitoring. Mobile application. Artificial intelligence. Citizen Science.

1 Introdução

As inundações e os alagamentos urbanos são eventos recorrentes em períodos de chuva intensa e podem gerar impactos significativos à população, como prejuízos materiais, dificuldades de deslocamento, interrupção de serviços e riscos à segurança das pessoas (TUCCI, 2007; IPEA, 2012). Em áreas urbanas, esses problemas tendem a ser agravados por fatores como impermeabilização do solo, ocupação de áreas suscetíveis, crescimento urbano desordenado e limitações nos sistemas de drenagem (TUCCI, 2007; FARIAS, 2022).

Além dos impactos físicos, a falta de informações atualizadas sobre as áreas afetadas dificulta a tomada de decisão durante situações de risco. Em muitos casos, moradores, motoristas e gestores públicos dependem de relatos informais ou de canais dispersos para compreender quais vias ou regiões estão alagadas. Essa limitação pode comprometer a mobilidade, atrasar respostas e aumentar a exposição da população a situações perigosas (CASTRO; FIGUEIREDO; NASCIMENTO, 2024; HIRATA et al., 2013).

Nesse contexto, tecnologias digitais podem apoiar o monitoramento e a disseminação de informações em tempo real. Aplicativos móveis, em especial, permitem integrar recursos como geolocalização, mapas interativos, notificações e envio de registros pelos usuários, aproximando a informação da realidade observada pela comunidade (CASTRO; FIGUEIREDO; NASCIMENTO, 2024). Além disso, iniciativas baseadas em participação cidadã podem complementar dados oficiais e ampliar a percepção espacial dos eventos, especialmente em locais onde o monitoramento institucional é limitado (HIRATA et al., 2013; HILLEBRAND et al., 2026).

Com base nesse cenário, este trabalho desenvolve um aplicativo móvel para o monitoramento colaborativo de áreas alagadas. A solução permite que usuários registrem pontos de alagamento em um mapa interativo, informando localização, nível de severidade e imagem do local. Os registros são encaminhados para análise em um painel administrativo, no qual podem ser revisados antes de serem disponibilizados à comunidade.

O sistema também incorpora a análise de imagens por inteligência artificial (IA) como recurso de apoio à triagem dos registros enviados. Em contextos de emergências e desastres, técnicas de IA têm sido investigadas como suporte à classificação, priorização e organização de informações (TAHERNEJAD et al., 2024). Neste trabalho, a IA não substitui a avaliação humana, mas atua como apoio para identificar indícios visuais de alagamento e auxiliar a revisão das contribuições recebidas.

1.1 Objetivos

1.1.1 Objetivo Geral

Desenvolver um aplicativo móvel colaborativo que permita à população registrar e visualizar, em tempo real, pontos de alagamento em áreas urbanas, com

o intuito de melhorar a comunicação comunitária, apoiar a tomada de decisão e contribuir para a redução dos impactos causados por inundações e áreas alagadas.

1.1.2 Objetivos Específicos

- Identificar trabalhos relacionados ao monitoramento de alagamentos, enchentes e inundações urbanas, considerando soluções baseadas em aplicativos móveis, sistemas *web*, geolocalização, participação colaborativa e IA.
- Avaliar diferentes modelos multimodais de IA abertos, executados localmente, comparando seu desempenho na triagem de imagens de alagamentos urbanos e na identificação de registros suspeitos, inválidos ou manipulados.
- Integrar um sistema de IA para auxiliar na análise de imagens enviadas pelos usuários, identificando registros inconsistentes, irrelevantes ou que não estejam relacionados a situações de alagamento.

1.2 Justificativa

A realização deste trabalho justifica-se pela necessidade de ferramentas acessíveis que auxiliem a população na identificação de áreas alagadas durante períodos de chuva intensa. Embora existam sistemas oficiais de monitoramento hidrometeorológico e canais oficiais de alerta, essas informações nem sempre representam, com detalhamento suficiente, a situação observada em ruas, bairros e trajetos cotidianos. Essa lacuna é especialmente relevante em cidades de pequeno e médio porte, onde a comunicação sobre pontos afetados pode depender de relatos dispersos entre moradores (HILLEBRAND et al., 2026; KOBİYAMA et al., 2024; CASTRO; FIGUEIREDO; NASCIMENTO, 2024).

A proposta do aplicativo busca responder a essa necessidade por meio de uma solução colaborativa, na qual a própria comunidade pode registrar e consultar ocorrências em um mapa interativo. Esse modelo favorece a construção de uma visão mais localizada do problema, permitindo que os usuários acompanhem os pontos afetados e tomem decisões mais seguras sobre seus deslocamentos. Ao mesmo tempo, os dados enviados podem oferecer aos gestores uma fonte complementar de informação sobre áreas recorrentes ou críticas.

Outro ponto que justifica o projeto é a preocupação com a confiabilidade dos registros. Plataformas colaborativas dependem da participação dos usuários, mas também precisam de mecanismos que reduzam informações incorretas, duplicadas ou inadequadas. Por isso, a aplicação combina autenticação via *Short Message Service* (SMS), envio de imagens, registro de localização e revisão administrativa das ocorrências antes da publicação.

A autenticação via SMS, nesse contexto, fortalece o processo de validação ao vincular cada relato a um número de telefone validado. Embora esse recurso não impeça todos os usos indevidos, ele aumenta a rastreabilidade dos envios, reduz o

anonimato completo e cria uma barreira inicial contra registros repetidos ou sem identificação mínima.

A inclusão da IA amplia essa proposta ao oferecer apoio à análise preliminar das imagens enviadas. Como os registros podem variar em qualidade, relevância e clareza, a IA pode auxiliar na identificação de imagens que apresentam ou não indícios de alagamento, contribuindo para organizar o fluxo de revisão no painel administrativo (TAHERNEJAD et al., 2024). Assim, a tecnologia é utilizada como suporte ao processo de triagem, mantendo a decisão final sob responsabilidade humana.

Dessa forma, o trabalho contribui tanto do ponto de vista social quanto tecnológico. Socialmente, propõe uma ferramenta voltada à comunicação comunitária e ao apoio à tomada de decisão em situações de risco. Tecnicamente, integra recursos de geolocalização, mapas interativos, autenticação, envio de imagens, painel administrativo e análise por IA em uma solução aplicada ao monitoramento colaborativo de áreas alagadas.

1.3 Método

O método adotado neste trabalho foi organizado em etapas relacionadas ao desenvolvimento da aplicação, à avaliação dos modelos de IA e à identificação de trabalhos relacionados. Esta seção apresenta a visão geral do processo metodológico.

A primeira etapa consistiu na definição do problema que o sistema buscaria atender: facilitar o registro e a visualização de áreas alagadas. A partir dessa definição, foram levantados os requisitos considerados essenciais para o primeiro protótipo, como o cadastro de ocorrências, o envio de imagens, a marcação da localização no mapa e a validação dos registros antes da publicação para a comunidade.

Em seguida, foram criadas as telas iniciais no Figma¹. Nessa parte, o foco foi organizar o caminho que o usuário faria dentro do aplicativo, desde o *login* até o envio de uma ocorrência. Também foram planejadas telas para visualizar os pontos de alagamento no mapa e acompanhar as contribuições feitas pelo próprio usuário.

Após a prototipação, iniciou-se o desenvolvimento da aplicação. O aplicativo móvel foi feito com React Native² e TypeScript³. No *backend*, foram usados Node.js⁴ e Express⁵, com PostgreSQL⁶ para o banco de dados e Prisma ORM⁷ para a comunicação com as tabelas. Além dessas tecnologias, o sistema precisou integrar recursos externos, como autenticação por SMS, armazenamento das imagens enviadas e uso da localização do dispositivo para registrar o ponto da ocorrência.

A aplicação foi dividida em duas partes principais. A primeira é o aplicativo

¹ <<https://www.figma.com/>>
² <<https://reactnative.dev/>>
³ <<https://www.typescriptlang.org/>>
⁴ <<https://nodejs.org/>>
⁵ <<https://expressjs.com/>>
⁶ <<https://www.postgresql.org/>>
⁷ <<https://www.prisma.io/>>

móvel, usado pelos moradores para cadastrar pontos de alagamento com localização, severidade e imagem. A segunda é o painel administrativo *web*, usado pelos gestores para verificar os registros recebidos e decidir se eles devem aparecer para os demais usuários. A análise dos relatos também conta com o apoio de IA, principalmente para verificar se a imagem enviada apresenta indícios compatíveis com uma situação de alagamento.

Durante o desenvolvimento, também foram realizados testes com modelos multimodais de IA para avaliar imagens associadas às ocorrências. Essa experimentação comparou diferentes modelos e diferentes *prompts*, observando a capacidade de reconhecer sinais de alagamento, indicar a gravidade aproximada e apontar possíveis registros inadequados. O procedimento específico da experimentação, incluindo coleta das imagens, avaliação humana, execução dos modelos, organização dos resultados e cálculo das métricas, é descrito na Seção 5.1.

Para contextualizar a proposta em relação a estudos existentes, foi empregada uma revisão sistemática da literatura sobre monitoramento de alagamentos, enchentes e inundações urbanas. Essa etapa foi organizada em planejamento, execução e resultados, conforme descrito na Seção 6. O objetivo foi identificar estudos que envolvessem soluções tecnológicas, aplicativos móveis, sistemas *web*, geolocalização, participação colaborativa ou IA aplicados ao tema.

O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta a fundamentação teórica, abordando os conceitos relacionados a inundações, áreas alagadas, monitoramento colaborativo, aplicativos móveis, geolocalização e IA aplicada à análise de imagens. A Seção 3 descreve a proposta do sistema, incluindo os requisitos funcionais, a arquitetura adotada, as tecnologias utilizadas e o fluxo principal do aplicativo. A Seção 4 descreve os resultados do desenvolvimento da aplicação, incluindo a modelagem de dados, as telas do aplicativo e o painel administrativo. A Seção 5 apresenta a experimentação com modelos multimodais de IA e a análise dos resultados obtidos. A Seção 6 apresenta os trabalhos relacionados, com os critérios de seleção e a estratégia de busca utilizada. Por fim, a Seção 7 apresenta as considerações finais do trabalho.

2 Fundamentação Teórica

A fundamentação teórica reúne os conceitos que sustentam a proposta do aplicativo e a etapa de triagem automatizada das imagens. A seção parte da discussão sobre desastres hidrológicos em áreas urbanas, passa pela participação cidadã no monitoramento de ocorrências e chega aos recursos computacionais usados para registrar, organizar e avaliar informações sobre alagamentos. Essa organização permite relacionar o problema tratado no trabalho com as decisões adotadas no desenvolvimento do sistema e na avaliação dos modelos de IA.

2.1 Desastres hidrológicos e áreas urbanas alagadas

Esta subseção apresenta conceitos necessários para compreender a ocorrência de áreas alagadas em contextos urbanos. Primeiro, são discutidas as relações entre desastres naturais, risco e vulnerabilidade. Depois, são diferenciados os conceitos de inundação, enchente e alagamento. Por fim, é abordado o papel do monitoramento hidrometeorológico e da informação local na identificação de situações de risco.

2.1.1 Desastres naturais, risco e vulnerabilidade

Desastres podem ser compreendidos como eventos adversos que provocam perturbações significativas no funcionamento de uma comunidade, superando sua capacidade local de resposta. Esses eventos podem estar associados a ameaças naturais, incidentes tecnológicos ou ações humanas, e seus efeitos incluem perdas humanas, danos materiais, impactos ambientais e prejuízos sociais (TAHERNEJAD et al., 2024). Quando a origem do evento está relacionada a processos naturais, como chuvas intensas, inundações, escorregamentos ou tempestades, utiliza-se a expressão desastre natural (TAHERNEJAD et al., 2024).

No contexto urbano, o desastre não depende apenas da ocorrência de um fenômeno natural. A intensidade dos impactos também está relacionada às condições de exposição e vulnerabilidade da população. Assim, uma chuva intensa pode produzir consequências distintas conforme o grau de ocupação do território, a capacidade da drenagem urbana, a presença de moradias em áreas suscetíveis e a existência de mecanismos de alerta e resposta (TUCCI, 2007; FARIAS, 2022; AJIN et al., 2025). Essa relação é importante porque desloca a análise do evento físico para as condições sociais e territoriais que tornam determinados grupos mais afetados.

A literatura sobre risco de inundação costuma tratar o risco como resultado da interação entre ameaça, vulnerabilidade e exposição. A ameaça está associada à possibilidade de ocorrência do fenômeno; a vulnerabilidade diz respeito à capacidade de uma população ou estrutura resistir e se recuperar; e a exposição envolve pessoas, moradias, infraestruturas e outros bens localizados em áreas suscetíveis (AJIN et al., 2025). Essa abordagem permite compreender que o monitoramento de áreas alagadas não se limita ao registro da presença de água. Ele também se relaciona à identificação de locais recorrentes, rotas afetadas e pontos críticos para a tomada de decisão.

2.1.2 Inundações, enchentes e alagamentos

As inundações, enchentes e alagamentos são fenômenos hidrológicos relacionados ao excesso de água em uma determinada área, mas não representam exatamente a mesma situação. A enchente está associada ao aumento do nível de um curso d'água, geralmente em razão de precipitações intensas ou acumuladas. Quando esse aumento ultrapassa a calha normal do rio e atinge áreas marginais, ocorre a inundação (TUCCI, 2007; FARIAS, 2022). Já o alagamento urbano costuma estar relacionado ao acúmulo temporário de água em ruas, avenidas e áreas rebaixadas,

muitas vezes provocado por insuficiência ou obstrução da drenagem pluvial (TUCCI, 2007; FARIAS, 2022).

Essa diferenciação é relevante porque cada fenômeno pode exigir formas distintas de monitoramento. Em áreas próximas a rios, o acompanhamento do nível da água e da cota de transbordamento pode ser decisivo para antecipar situações de inundação. Em áreas urbanas densamente ocupadas, por outro lado, pontos de alagamento podem surgir de forma localizada, mesmo sem transbordamento direto de um curso d'água. Nesses casos, informações sobre ruas bloqueadas, pontos com água acumulada e imagens do local podem complementar dados hidrometeorológicos oficiais.

A ocorrência desses eventos em cidades é intensificada por fatores como impermeabilização do solo, canalização de cursos d'água, descarte inadequado de resíduos, ocupação de áreas suscetíveis e limitações nos sistemas de drenagem (TUCCI, 2007; FARIAS, 2022). Em bacias urbanizadas, a água da chuva tende a infiltrar menos no solo e escoar mais rapidamente pela superfície. Esse processo aumenta a velocidade de resposta da bacia e pode ampliar a frequência de pontos críticos durante chuvas intensas.

Além dos danos diretos, áreas alagadas podem afetar a mobilidade urbana e a segurança da população. Vias interrompidas, dificuldade de deslocamento, danos a veículos, bloqueios no acesso a serviços e exposição a água contaminada são consequências comuns em eventos desse tipo (TUCCI, 2007; FARIAS, 2022). Por isso, informações atualizadas sobre os locais afetados têm valor prático para moradores, motoristas, equipes de resposta e gestores públicos.

2.1.3 Monitoramento hidrometeorológico e informação local

O monitoramento hidrometeorológico é uma estratégia central para compreender a dinâmica de chuvas, níveis de rios e possíveis situações de risco. Redes de pluviômetros, estações meteorológicas, réguas linimétricas e sensores de nível permitem acompanhar variáveis importantes para a prevenção e resposta a desastres hidrológicos (HILLEBRAND et al., 2026). Esses dados são úteis para análises técnicas, emissão de alertas e planejamento de ações de defesa civil.

Apesar de sua importância, redes oficiais de monitoramento podem apresentar limitações de cobertura espacial, funcionamento ou atualização. Em bacias com poucos instrumentos, uma chuva intensa pode atingir áreas não monitoradas diretamente, dificultando a leitura da distribuição espacial do evento. O caso da Bacia Hidrográfica do Rio Rolante ilustra esse problema. Estudos sobre a região indicam que, no desastre de 2017, a ausência de estações oficiais em funcionamento na área afetada dificultou o registro completo do evento e exigiu a reconstrução posterior da precipitação com apoio de informações locais (HILLEBRAND et al., 2026).

Nesse cenário, dados produzidos pela comunidade podem complementar o monitoramento institucional. A participação de moradores na observação de rios, pluviômetros, réguas linimétricas e pontos de risco contribui para ampliar a percepção

territorial dos eventos ([KOBİYAMA et al., 2024](#); [HILLEBRAND et al., 2026](#)). Essa participação não substitui as medições técnicas, mas pode oferecer informações localizadas em áreas onde sensores oficiais são escassos ou inexistentes.

2.2 Participação cidadã e monitoramento colaborativo

Esta subseção discute a participação da população na produção de informações sobre situações de risco. Inicialmente, são apresentados conceitos relacionados à ciência cidadã, à bacia escola e à participação comunitária. Em seguida, o foco recai sobre o monitoramento colaborativo de áreas alagadas, considerando o envio de relatos, imagens e informações locais por moradores.

2.2.1 Ciência cidadã, bacia escola e participação comunitária

A ciência cidadã envolve a participação da população em atividades de observação, coleta, registro ou interpretação de dados relacionados a problemas reais. Em contextos de risco hidrológico, essa participação pode aproximar o conhecimento técnico da experiência cotidiana dos moradores. A proposta de bacia escola utiliza essa lógica ao integrar ciência, educação, comunidade local e governança territorial em um mesmo espaço de aprendizagem e monitoramento ([KOBİYAMA et al., 2024](#); [HILLEBRAND et al., 2026](#)).

A bacia escola é apresentada como uma tecnologia social voltada não apenas à pesquisa científica, mas também à educação, à formação cidadã e à redução de risco de desastres. Nesse modelo, instrumentos de monitoramento, como réguas linimétricas, sensores de nível e estações meteorológicas, são articulados a ações de capacitação com escolas, moradores e instituições locais ([KOBİYAMA et al., 2024](#); [HILLEBRAND et al., 2026](#)). A proposta busca desenvolver uma consciência do risco, permitindo que a população reconheça sinais de perigo e compreenda melhor a dinâmica da bacia onde vive.

A experiência da Bacia Escola do Rio Rolante também mostra que o engajamento comunitário pode produzir dados complementares às redes oficiais. No caso do desastre de 2017, informações não oficiais de agricultores locais foram utilizadas junto a dados de pluviômetros para reconstruir a distribuição espacial e temporal da chuva ([HILLEBRAND et al., 2026](#)). Esse exemplo reforça a importância de considerar o conhecimento local como parte do processo de monitoramento, principalmente em regiões com deficiência de medições formais.

2.2.2 Monitoramento colaborativo em áreas alagadas

O monitoramento colaborativo pode ser entendido como um processo em que diferentes pessoas contribuem com informações sobre uma situação observada em campo. Em eventos de alagamento, essa colaboração pode ocorrer por meio do envio de relatos, imagens, localização e descrição da severidade percebida. A vantagem desse modelo está na possibilidade de ampliar a cobertura espacial das informações,

já que moradores distribuídos pelo território conseguem registrar pontos afetados em diferentes bairros e vias (SULISTYO et al., 2025; NARAYANAN et al., 2014).

Esse tipo de colaboração é especialmente útil em eventos rápidos e localizados. Alagamentos urbanos podem surgir em pontos específicos da cidade e desaparecer em poucas horas. Por isso, nem sempre são capturados por estações oficiais ou por levantamentos realizados posteriormente. Relatos enviados pela população podem ajudar a indicar onde a água se acumulou, quais vias ficaram comprometidas e quais regiões exigem atenção imediata (SULISTYO et al., 2025; HILLEBRAND et al., 2026).

No entanto, plataformas colaborativas também enfrentam desafios. As informações enviadas podem variar em qualidade, precisão e relevância. Um relato pode estar incompleto, duplicado, mal localizado ou não representar uma situação real de alagamento. Por esse motivo, mecanismos de validação são necessários para reduzir ruídos e aumentar a confiabilidade dos dados publicados. A revisão por gestores, a exigência de evidência visual e a análise automatizada de imagens são exemplos de recursos que podem apoiar esse processo (NARAYANAN et al., 2014; SULISTYO et al., 2025).

2.3 Tecnologias computacionais aplicadas ao monitoramento de alagamentos

Esta subseção apresenta recursos computacionais utilizados no monitoramento e na comunicação de ocorrências de alagamento. São abordados aplicativos móveis, geolocalização, mapas interativos, evidências visuais e técnicas de visão computacional. Esses elementos ajudam a relacionar os conceitos discutidos anteriormente com a proposta tecnológica desenvolvida neste trabalho.

2.3.1 Aplicativos móveis e comunicação de risco

Aplicativos móveis podem apoiar a comunicação de risco ao reunir informações relevantes em um canal de acesso rápido. Em situações de enchentes, estudos apontam funcionalidades como alertas, notícias, acompanhamento do nível da água, localização do usuário e contatos de emergência (CASTRO; FIGUEIREDO; NASCIMENTO, 2024). Esses recursos aproximam a informação da rotina da população, pois permitem consultar dados sobre a área de interesse e receber avisos quando houver risco.

O protótipo Enchentes SOS, por exemplo, foi desenvolvido com o objetivo de oferecer informações sobre níveis de rios, notícias e alertas para moradores de uma cidade afetada por enchentes recorrentes (CASTRO; FIGUEIREDO; NASCIMENTO, 2024). O estudo destaca que a falta de comunicação eficiente pode fazer com que moradores percebam a elevação do nível da água apenas quando a situação já está avançada. Nesse caso, o aplicativo é tratado como uma alternativa para organizar informações e facilitar ações preventivas.

Em sistemas voltados a alagamentos urbanos, o aplicativo móvel também pode funcionar como canal de coleta de dados. O usuário deixa de ser apenas receptor de

alertas e passa a contribuir com registros sobre a situação observada. Essa mudança amplia o papel da aplicação: além de comunicar riscos, ela pode apoiar o mapeamento colaborativo de pontos afetados.

2.3.2 Geolocalização, mapas interativos e evidências visuais

A geolocalização é um recurso importante para associar informações a uma posição específica no território. Em aplicações de monitoramento de alagamentos, a localização permite representar os relatos em mapas, identificar proximidade entre ocorrências e apoiar decisões sobre deslocamento. Quando combinada a mapas interativos, essa informação facilita a visualização espacial dos pontos afetados.

O uso de imagens georreferenciadas também aparece em estudos sobre sensoriamento participativo. [Narayanan et al. \(2014\)](#) propuseram uma abordagem em que participantes capturam e enviam imagens de estruturas parcialmente submersas, como prédios e postes, usando smartphones ou dispositivos inteligentes. As imagens são georreferenciadas e enviadas a um servidor para análise com técnicas de visão computacional. Essa abordagem demonstra como registros visuais enviados por usuários podem contribuir para estimar níveis de inundação em diferentes locais.

As evidências visuais têm duas funções principais. A primeira é apoiar a compreensão humana da ocorrência, permitindo verificar se o local realmente apresenta acúmulo de água. A segunda é fornecer insumos para técnicas computacionais de análise de imagem. Em ambos os casos, a imagem precisa ser avaliada com cuidado, pois fotos de baixa qualidade, registros fora do contexto ou imagens manipuladas podem comprometer a confiabilidade da informação.

2.3.3 Visão computacional e análise de imagens em eventos de inundação

A visão computacional tem sido usada para extrair informações de imagens relacionadas a inundações. Em trabalhos anteriores, imagens de estruturas fixas, objetos urbanos ou sinais de trânsito foram usadas como referência para estimar profundidade da água e mapear áreas inundadas ([NARAYANAN et al., 2014](#); [ALIZADEH; BEHZADAN, 2023](#)). Essas abordagens exploram o fato de que objetos presentes no ambiente urbano podem servir como marcadores visuais para interpretar o nível da água.

[Alizadeh e Behzadan \(2023\)](#) propuseram o uso de fotografias colaborativas de placas de trânsito submersas para estimar a profundidade da água em nível de rua. O método combina redes neurais convolucionais profundas com a comparação entre partes visíveis das placas antes e depois do evento de inundação. O estudo reforça que informações rápidas e espacialmente detalhadas sobre profundidade da água são relevantes para o deslocamento seguro de pessoas e para a atuação de equipes de resposta.

[Narayanan et al. \(2014\)](#) também utilizaram visão computacional em uma abordagem participativa. O método compara imagens capturadas durante a inundação com imagens de referência, usando correspondência de pontos e matriz de homografia

para estimar a linha de inundação. Embora o estudo tenha sido experimental, ele mostra que imagens enviadas por participantes podem auxiliar na identificação de áreas severamente afetadas, desde que haja procedimentos de análise e validação adequados.

Esses trabalhos indicam que a análise automatizada de imagens pode apoiar o monitoramento de alagamentos, mas também evidenciam limitações. A qualidade da imagem, o ângulo de captura, a distância do objeto, a disponibilidade de referências e a presença de ruídos podem afetar os resultados ([NARAYANAN et al., 2014](#); [ALIZADEH; BEHZADAN, 2023](#)). Por isso, em aplicações voltadas à população, a análise computacional deve ser tratada como apoio à interpretação, e não como única fonte de decisão.

2.4 Inteligência artificial e triagem de informações

Esta subseção apresenta conceitos relacionados ao uso de inteligência artificial na organização e validação de informações em situações de emergência. Primeiro, discute-se a ideia de triagem e sua aplicação em contextos com grande volume de dados. Depois, é abordado o uso da IA como apoio à validação de imagens. Por fim, são apresentadas a matriz de confusão e as métricas utilizadas para avaliar os modelos de classificação neste trabalho.

2.4.1 Triagem em situações de emergência

A triagem é o processo de classificar e priorizar informações, pessoas ou ocorrências conforme critérios definidos. Em emergências e desastres, sua finalidade é apoiar decisões rápidas em cenários com recursos limitados e grande volume de dados ([TAHERNEJAD et al., 2024](#)). Embora o conceito seja frequentemente associado ao atendimento de vítimas, a lógica de triagem também pode ser aplicada à organização de registros e evidências recebidas durante uma situação crítica.

Sistemas tradicionais de triagem apresentam limitações, especialmente quando dependem de preenchimento manual, etiquetas físicas ou interpretação sob pressão. [Tahernejad et al. \(2024\)](#) destacam que a contagem manual, a dificuldade de visualização e a ausência de informações completas podem gerar erros e prejudicar o gerenciamento da cena. Em ambientes digitais, problemas semelhantes podem ocorrer quando muitos registros chegam ao mesmo tempo e precisam ser avaliados por uma equipe reduzida.

A triagem automatizada busca apoiar esse processo por meio de algoritmos capazes de classificar, ordenar ou sinalizar informações. Na revisão sistemática de [Tahernejad et al. \(2024\)](#), sistemas baseados em IA foram associados à otimização de recursos, transmissão de dados em tempo real e apoio à tomada de decisão em emergências. Os autores também apontam desafios de implementação, como confiança nos sistemas, necessidade de treinamento, disponibilidade de equipamentos e privacidade dos dados.

2.4.2 Inteligência artificial como apoio à validação de imagens

No monitoramento colaborativo de áreas alagadas, a IA pode ser usada para apoiar a validação preliminar das imagens enviadas. Essa validação pode observar se a imagem apresenta indícios visuais de alagamento, se parece estar relacionada ao ambiente urbano e se contém sinais de inconsistência. A análise automatizada pode reduzir o esforço inicial da equipe responsável pela revisão, principalmente quando há grande volume de registros.

A IA, nesse contexto, não deve substituir a avaliação humana. A decisão sobre aprovar ou rejeitar um relato envolve elementos que podem não estar totalmente presentes na imagem, como localização, histórico do ponto, contexto do evento e possibilidade de erro no envio. Assim, a análise automatizada deve funcionar como uma camada de apoio. Ela pode indicar prioridades, apontar registros duvidosos e organizar o fluxo de conferência.

Essa abordagem é coerente com estudos que discutem o uso de IA em emergências e desastres. A literatura mostra que modelos inteligentes podem contribuir para classificação e priorização, mas sua adoção exige atenção a confiabilidade, transparência, treinamento dos usuários e proteção dos dados (TAHERNEJAD et al., 2024). Em aplicações colaborativas, esses cuidados são ainda mais importantes, pois as informações são produzidas por diferentes pessoas e podem ter níveis variados de qualidade.

2.4.3 Matriz de confusão e métricas de avaliação

A avaliação de modelos de classificação pode ser realizada por meio da comparação entre os valores previstos pelo modelo e os valores reais de um conjunto de dados. Uma das formas mais utilizadas para organizar essa comparação é a matriz de confusão, também chamada de matriz de erro. Essa matriz apresenta os acertos e erros do classificador a partir da relação entre as classes reais e as classes previstas (TING, 2018).

Em problemas de classificação binária, a matriz de confusão é composta por quatro resultados principais: verdadeiro positivo, falso positivo, verdadeiro negativo e falso negativo. O verdadeiro positivo ocorre quando o modelo classifica corretamente uma instância positiva. O falso positivo ocorre quando uma instância negativa é classificada incorretamente como positiva. O verdadeiro negativo representa a classificação correta de uma instância negativa. Já o falso negativo ocorre quando uma instância positiva é classificada como negativa (TING, 2018).

A partir desses valores, é possível calcular métricas que auxiliam na interpretação do desempenho do modelo. Neste trabalho, foram utilizadas acurácia, precisão, *recall* e *F1-score*. A acurácia representa a proporção geral de classificações corretas em relação ao total de exemplos avaliados. Embora seja uma métrica útil, ela pode não ser suficiente em bases desbalanceadas, pois um modelo pode apresentar alta acurácia mesmo com desempenho ruim em uma das classes (KUHN; JOHNSON, 2016).

A precisão indica a proporção de predições positivas que realmente pertencem à classe positiva. No contexto deste trabalho, essa métrica ajuda a observar quantas imagens classificadas como válidas pelo modelo eram, de fato, válidas segundo a avaliação humana (ZHANG; ZHANG, 2018). O *recall*, também chamado de sensibilidade, mede a capacidade do modelo de identificar corretamente as instâncias positivas existentes na base (ZHANG; ZHANG, 2018).

O *F1-score* combina precisão e *recall* por meio da média harmônica. Essa métrica é útil quando se deseja observar o equilíbrio entre a capacidade do modelo de acertar suas predições positivas e a capacidade de recuperar corretamente os casos positivos existentes (CARTERETTE, 2018; GOODFELLOW; BENGIO; COURVILLE, 2016; MURPHY, 2012).

No caso deste estudo, essas métricas foram utilizadas para avaliar a capacidade dos modelos de IA em decidir se uma imagem poderia ou não ser aceita no aplicativo. Assim, a avaliação não se limitou à identificação de alagamento. Também considerou a validade da imagem como evidência, incluindo casos de imagens suspeitas, manipuladas, inválidas ou sem alagamento urbano visível.

2.5 Síntese da fundamentação

A fundamentação apresentada mostra que o monitoramento de áreas alagadas envolve tanto conceitos hidrológicos quanto recursos computacionais. Do ponto de vista dos desastres, é necessário compreender a diferença entre enchentes, inundações e alagamentos, além da relação entre ameaça, vulnerabilidade e exposição. Do ponto de vista social, a participação cidadã pode ampliar a cobertura das informações e complementar redes oficiais de monitoramento.

No campo tecnológico, aplicativos móveis, geolocalização, mapas interativos, envio de imagens e visão computacional oferecem recursos úteis para registrar e interpretar ocorrências. A IA pode apoiar a triagem das imagens, desde que seja usada como suporte à análise humana. Essa combinação permite construir soluções voltadas à comunicação comunitária, à organização de registros e ao apoio à tomada de decisão em situações de chuva intensa.

3 Proposta

A proposta deste trabalho é desenvolver um aplicativo móvel colaborativo voltado ao monitoramento de áreas alagadas urbanas, com foco no apoio à comunicação comunitária e à visualização de pontos afetados em tempo real. Para isso, a seção foi organizada em três partes. Primeiro, são apresentados os requisitos funcionais que orientaram a definição das funcionalidades do sistema. Em seguida, são descritas a arquitetura adotada e as tecnologias utilizadas na implementação. Por fim, são apresentados os fluxos de interação que representam o funcionamento das principais operações do aplicativo.

3.1 Requisitos Funcionais

Os requisitos funcionais foram definidos a partir dos fluxos previstos para o aplicativo móvel, para o *backend* e para o painel administrativo. Eles indicam quais ações o sistema deve permitir, bloquear ou executar automaticamente durante o uso. A organização foi feita por grupos de funcionalidades, pois cada parte do sistema possui responsabilidades diferentes.

O primeiro grupo reúne os requisitos de autenticação. No aplicativo, o envio de relatos, o acesso ao histórico e as respostas colaborativas não ficam disponíveis para usuários sem identificação. Por isso, o acesso foi associado ao número de telefone, com envio de código de verificação por SMS. Quando o código é validado, o sistema cria um *token* de sessão⁸. Esse registro fica salvo no dispositivo e tem validade limitada. Os requisitos desse fluxo estão descritos na Tabela 1.

Tabela 1 – Requisitos funcionais para autenticação de usuário.

Código	Descrição
RF01	O sistema deve permitir a autenticação do usuário por número de telefone.
RF02	O sistema deve enviar um código de verificação de uso único por SMS para o telefone informado.
RF03	O sistema deve validar o código de verificação informado pelo usuário.
RF04	O sistema deve autenticar o usuário após a validação bem-sucedida do código.
RF05	O sistema deve manter a sessão do usuário ativa por meio de um <i>token</i> salvo no dispositivo.
RF06	O <i>token</i> de autenticação do usuário deve ter duração padrão de 8 horas, com tempo de expiração configurável por variável de ambiente.
RF07	O sistema deve verificar automaticamente a validade da sessão ao iniciar o aplicativo.
RF08	O sistema deve encerrar a sessão quando o <i>token</i> estiver expirado ou quando o usuário fizer <i>logout</i> .
RF09	O sistema deve restringir funcionalidades protegidas a usuários autenticados.
RF10	O sistema deve solicitar autenticação quando o usuário tentar executar uma ação que exige <i>login</i> .

Fonte: Elaborado pela autora.

A visualização dos pontos de alagamento foi separada dos fluxos protegidos por autenticação, pois o mapa precisa estar disponível para consulta pública. Essa decisão permite que qualquer usuário acompanhe as áreas registradas, enquanto informações em análise permanecem visíveis apenas para quem realizou a marcação. A Tabela 2 reúne os requisitos relacionados a esse comportamento.

A marcação de pontos concentra as ações necessárias para registrar uma possível área alagada. Esse fluxo depende da seleção do local no mapa, da permissão de localização, da validação da distância entre o usuário e o ponto informado, do envio de uma imagem e da indicação do nível do alagamento. Essas regras foram definidas para reduzir registros imprecisos e manter um padrão mínimo de informação antes da análise da ocorrência. Os requisitos desse processo estão organizados na Tabela 3.

⁸ Neste trabalho, *token* de sessão é o código digital gerado pelo sistema para manter o usuário identificado durante uma sessão.

Tabela 2 – Requisitos funcionais para visualização de dados.

Código	Descrição
RF11	O sistema deve disponibilizar um <i>endpoint</i> público para consulta dos pontos de alagamento exibidos no mapa, sem exigir autenticação do usuário.
RF12	O sistema deve exibir no mapa os pontos de alagamento registrados.
RF13	O sistema deve apresentar os pontos de alagamento como marcadores no mapa interativo.
RF14	O sistema deve permitir selecionar um ponto de alagamento no mapa.
RF15	Ao selecionar um ponto, o sistema deve exibir informações da área alagada, incluindo endereço ou local aproximado, nível do alagamento e imagens vinculadas ao ponto.
RF16	O sistema deve exibir pontos com <i>status</i> “em análise” apenas para o usuário que realizou a marcação.

Fonte: Elaborado pela autora.

Tabela 3 – Requisitos funcionais para marcação de pontos de alagamento.

Código	Descrição
RF17	O sistema deve exibir um mapa interativo para visualização das áreas geográficas.
RF18	O sistema deve exibir a localização atual do usuário no mapa, quando a permissão de localização estiver concedida.
RF19	O sistema deve solicitar acesso à localização do dispositivo quando a permissão ainda não tiver sido concedida.
RF20	O sistema deve permitir que o usuário selecione um ponto no mapa para registrar uma possível área alagada.
RF21	O sistema deve solicitar a confirmação do ponto selecionado antes de iniciar o registro da ocorrência.
RF22	O sistema deve validar se o ponto selecionado está dentro do raio permitido de 100 metros em relação à localização atual do usuário.
RF23	O sistema deve impedir o registro caso o ponto selecionado esteja fora do raio permitido de 100 metros.
RF24	O sistema deve exigir uma imagem como comprovação da ocorrência de alagamento.
RF25	O sistema deve exigir a indicação do nível do alagamento.
RF26	O sistema deve permitir classificar o alagamento como leve, moderado ou interditado.
RF27	O sistema deve exigir autenticação do usuário antes de concluir o envio da marcação, caso o usuário não esteja autenticado.
RF28	O sistema deve enviar a ocorrência com a localização marcada, a localização atual do usuário, a imagem, o nível do alagamento e o <i>status</i> inicial “em análise”.
RF29	O sistema deve exibir no mapa as áreas de alagamento já registradas e ativas.

Fonte: Elaborado pela autora.

As notificações foram previstas para permitir que o usuário acompanhe alertas de acordo com regiões de interesse. Para isso, o sistema deve salvar preferências por estado e cidade, além de solicitar permissão para envio de notificações no dispositivo. Esse fluxo também exige autenticação, pois as preferências ficam associadas ao usuário. A Tabela 4 apresenta os requisitos dessa funcionalidade.

O histórico de marcações permite que o usuário acompanhe os relatos enviados por ele. Esse recurso é restrito a usuários autenticados e reúne informações como local, data e *status* da ocorrência. Assim, o usuário consegue verificar se a marcação ainda está em análise, se foi aprovada ou se foi rejeitada. Os requisitos do histórico

Tabela 4 – Requisitos funcionais para configuração de notificações.

Código	Descrição
RF30	O sistema deve permitir que o usuário configure preferências de recebimento de notificações.
RF31	O sistema deve exigir autenticação para salvar preferências de notificação.
RF32	O sistema deve permitir que o usuário selecione um estado.
RF33	Após a seleção do estado, o sistema deve carregar as cidades disponíveis para aquele estado.
RF34	O sistema deve permitir que o usuário selecione uma ou mais cidades para receber alertas.
RF35	O sistema deve permitir remover cidades previamente selecionadas antes de salvar.
RF36	O sistema deve solicitar permissão para envio de notificações no dispositivo.
RF37	O sistema deve obter o token de notificação push do dispositivo quando a permissão for concedida.
RF38	O sistema deve salvar as preferências do usuário contendo estado, cidades e token de notificação.
RF39	Caso a permissão de notificação seja negada, o sistema deve orientar o usuário a ativá-la nas configurações do dispositivo.

Fonte: Elaborado pela autora.

estão descritos na Tabela 5.

Tabela 5 – Requisitos funcionais para histórico de marcações.

Código	Descrição
RF40	O sistema deve permitir que o usuário autenticado visualize o histórico de suas marcações de alagamento.
RF41	O sistema deve restringir o acesso ao histórico apenas para usuários autenticados.
RF42	O sistema deve listar as ocorrências do histórico em ordem da mais recente para a mais antiga.
RF43	O sistema deve exibir, para cada ocorrência do histórico, o endereço/local registrado, a data de criação e o status da ocorrência.
RF44	O sistema deve diferenciar visualmente os status das ocorrências, como “em análise”, “aprovado” ou “rejeitado”.
RF45	O sistema deve informar quando nenhum histórico for encontrado para o usuário.
RF46	O sistema deve permitir selecionar uma ocorrência do histórico para visualizar seus detalhes.

Fonte: Elaborado pela autora.

A validação colaborativa por proximidade foi definida para atualizar a condição dos pontos já registrados. Quando um usuário se aproxima de uma área ativa, o sistema pode solicitar uma confirmação sobre a situação do local. Essa resposta ajuda a indicar se o alagamento permanece ou se o ponto deve deixar de aparecer na visualização pública. A Tabela 6 apresenta os requisitos associados a esse fluxo.

O painel administrativo reúne os recursos usados para analisar os relatos recebidos pelo sistema. Nesse módulo, os administradores podem consultar a lista de ocorrências, visualizar informações resumidas, aplicar filtros e acessar detalhes de um relato específico. Esses requisitos complementam o fluxo do aplicativo, pois

Tabela 6 – Requisitos funcionais para validação colaborativa por proximidade.

Código	Descrição
RF47	O sistema deve monitorar a proximidade do usuário em relação aos pontos de alagamento ativos.
RF48	O sistema deve identificar quando o usuário estiver a até 30 metros de uma área alagada registrada.
RF49	O sistema não deve exibir o alerta para áreas registradas pelo próprio usuário.
RF50	O sistema deve perguntar ao usuário próximo se a área ainda está alagada.
RF51	O sistema deve permitir que o usuário responda se a área ainda está ou não alagada.
RF52	O sistema deve exigir autenticação antes de registrar a resposta do usuário.
RF53	O sistema deve contabilizar respostas positivas e negativas sobre a condição atual da área.
RF54	O sistema deve evitar perguntar repetidamente ao mesmo usuário sobre a mesma área.
RF55	O sistema deve remover da visualização pública do mapa os pontos de alagamento após um período configurável de tempo.
RF56	O sistema deve remover da visualização pública do mapa os pontos de alagamento quando atingir uma quantidade configurável de respostas indicando que a área não está mais alagada.

Fonte: Elaborado pela autora.

tratam da etapa de análise posterior ao envio das marcações. A Tabela 7 organiza os requisitos dessa parte do sistema.

Tabela 7 – Requisitos funcionais para análise de alagamentos no painel administrativo.

Código	Descrição
RF57	O sistema administrativo deve permitir visualizar a lista de relatos de alagamento cadastrados.
RF58	O sistema deve exibir, para cada relato, o identificador, o endereço/local registrado, o nível do alagamento, o status de análise e a data de criação formatada.
RF59	O sistema deve diferenciar visualmente os níveis de alagamento e os status dos relatos.
RF60	O sistema deve permitir filtrar os relatos por nível de alagamento e por status de análise, além de permitir limpar os filtros aplicados.
RF61	O sistema deve informar quando nenhum relato for encontrado para os filtros selecionados.
RF62	O sistema deve permitir acessar a tela de detalhes de um relato selecionado.
RF63	O sistema deve permitir abrir a localização do relato em um serviço externo de mapas.
RF64	O sistema deve apresentar os textos da listagem conforme o idioma selecionado no painel administrativo.

Fonte: Elaborado pela autora.

3.2 Arquitetura e Tecnologias Utilizadas

A aplicação foi dividida em três partes: aplicativo móvel, *backend* e painel administrativo. Essa separação ajudou a organizar as responsabilidades do sistema. O aplicativo concentra as ações do usuário, o *backend* trata as regras e a comunicação

com o banco de dados, e o painel reúne as funções voltadas à administração dos registros. Esse painel foi desenvolvido com Next.js, por se tratar de uma interface *web* acessada pelos administradores.

No aplicativo móvel, foram usados React Native e TypeScript. A escolha permitiu desenvolver a versão para Android e iOS a partir da mesma base de código. O *backend* foi construído com Node.js e Express. Esse módulo ficou responsável pela lógica da aplicação, pela criação da *Application Programming Interface* (API) e pela integração com o PostgreSQL, utilizado para armazenar as informações do sistema.


3.3 Fluxos de Interação do Sistema

Os diagramas de sequência foram elaborados para representar a ordem das interações entre os principais componentes da aplicação. Esse tipo de representação ajuda a verificar se os requisitos descritos anteriormente estão coerentes com o funcionamento previsto para o sistema. Neste trabalho, foram modelados dois fluxos considerados centrais: a autenticação por telefone e o uso do aplicativo para consulta e envio de relatos de alagamento.

A Figura 1 representa o fluxo de autenticação por telefone. O processo considera a verificação de sessão ativa, o envio de código por SMS, a validação do código informado e a liberação das funcionalidades protegidas após a geração do token de sessão. A autenticação usa *One-Time Password* (OTP), ou senha de uso único. Conforme a MDN Web Docs, esse tipo de código é temporário e pode ser enviado por outro canal, como SMS ou e-mail (MDN Web Docs, 2025). Neste trabalho, o OTP foi usado para validar o telefone do usuário e liberar o acesso ao aplicativo sem senha tradicional.


A Figura 2 representa o fluxo principal de uso do aplicativo. O diagrama reúne a consulta de pontos ativos no mapa e o envio de um novo relato. A consulta permite que o usuário visualize os registros disponíveis, enquanto o envio do relato envolve a seleção do ponto, a captura da imagem, a indicação do nível do alagamento e o registro das informações no servidor. Com isso, o diagrama mostra como o aplicativo intermedia as ações do usuário e como o *backend* centraliza a comunicação com o banco de dados.

Figura 1 – Diagrama de sequência da autenticação por OTP via SMS.



Fonte: Elaborado pela autora

Figura 2 – Diagrama de sequência do fluxo principal do aplicativo.



Fonte: Elaborado pela autora.


4 Resultados do Desenvolvimento da Aplicação

Esta seção apresenta os resultados obtidos a partir do desenvolvimento da aplicação. Primeiro, é descrita a modelagem de dados, com as tabelas utilizadas para armazenar usuários, relatos, imagens, notificações e análises realizadas pela IA. Em seguida, são apresentadas as telas do fluxo principal do aplicativo, desde a marcação do ponto de alagamento até a confirmação do envio. Por fim, é descrito o painel administrativo, utilizado para visualizar, filtrar, aprovar ou rejeitar os relatos enviados pela comunidade.

4.1 Modelagem de Dados

O banco de dados foi definido considerando os dados utilizados pelas principais funções do aplicativo, como cadastro de usuários, envio de alertas, notificações e registro dos pontos de alagamento. A Figura 3 mostra o modelo relacional utilizado no projeto, incluindo também as tabelas relacionadas às imagens, às análises dos relatos e ao painel administrativo.

Figura 3 – Modelagem de dados.



Fonte: Elaborado pela autora.

As tabelas do modelo são descritas a seguir:


- **tb_user:** Tabela destinada aos dados dos usuários do aplicativo, como telefone, localização e situação da conta.
- **tb_code:** Utilizada no processo de autenticação, mantendo os códigos enviados por SMS para validação do acesso.
- **tb_notification:** Concentra as notificações encaminhadas aos usuários.
- **tb_user_alert_preference:** Guarda as configurações de alerta escolhidas pelo usuário, considerando a cidade e o estado informados.
- **tb_user_device:** Mantém os *tokens* associados aos dispositivos, necessários para o envio de notificações *push*.
- **tb_flood_area:** Tabela central do sistema, pois reúne os relatos de alagamento enviados pela comunidade. Nela são registrados dados como endereço, coordenadas geográficas, cidade, estado, nível do alagamento, situação de aprovação, comentários administrativos e votos dos usuários.
- **tb_flood_level:** Lista os níveis de alagamento disponíveis para classificação dos relatos, como leve, moderado e interditado.
- **tb_images:** Relaciona as imagens enviadas pelos usuários aos respectivos pontos de alagamento.
- **tb_flood_area_ai_analysis:** Guarda o resultado do processamento das imagens pela IA. Entre os dados mantidos estão a indicação de possível alagamento, o grau de confiança da análise, a pontuação de veracidade, a descrição gerada e os metadados vinculados ao processamento.
- **tb_user_admin:** Reúne as contas administrativas utilizadas para acesso ao painel de gestão.
- **tb_user_admin_password_attempts:** Mantém o registro das tentativas de *login* no painel administrativo.
- **tb_faq:** Reúne as perguntas e respostas cadastradas para consulta dos usuários no aplicativo.

4.2 Telas do fluxo principal do aplicativo


O fluxo principal do aplicativo contempla duas formas de interação com o mapa. A primeira corresponde à consulta dos pontos de alagamento já registrados, permitindo que o usuário visualize as áreas afetadas e acesse informações básicas de cada ocorrência. A segunda corresponde ao envio de um novo relato, no qual o usuário marca o local, registra uma imagem e informa o nível do alagamento.

A Figura 4 apresenta a visualização inicial do mapa e a interação com um ponto de alagamento já cadastrado. Na primeira tela, o usuário visualiza os marcadores distribuídos no mapa, junto à sua localização atual. Na segunda, ao selecionar um marcador, são exibidas informações resumidas da ocorrência, como endereço, tempo desde a criação, nível do alagamento e acesso às imagens vinculadas ao registro.

Figura 4 – Visualização e consulta de pontos de alagamento registrados no mapa do aplicativo.



(a) Visualização dos pontos no mapa.




(b) Detalhes do ponto selecionado.


Fonte: Elaborado pela autora.

Para registrar uma nova ocorrência, o usuário seleciona no mapa o local afetado, captura uma imagem do alagamento, informa o nível da ocorrência e valida o envio por telefone. A Figura 5 apresenta essas etapas, desde a marcação inicial até a confirmação do registro.


Figura 5 – Fluxo de registro de um ponto de alagamento no aplicativo, incluindo marcação do local, captura da imagem, seleção do nível, validação por telefone, confirmação do código enviado por SMS e tela de sucesso.




(a) Marcação.



(b) Captura.




(c) Nível.



(d) Telefone.



(e) Código.



(f) Sucesso.

Fonte: Elaborado pela autora.


4.3 Painel administrativo

O painel administrativo concentra os relatos enviados pelo aplicativo e permite que a equipe responsável avalie cada registro antes de sua disponibilização no mapa. O acesso é restrito aos gestores cadastrados e ocorre por meio de *e-mail* e senha. Essa restrição evita que usuários não autorizados consultem os dados recebidos ou alterem a situação dos relatos.

A tela principal do painel apresenta a listagem dos relatos cadastrados no sistema. Nessa página, o gestor visualiza os dados necessários para uma primeira triagem, como endereço, nível do alagamento, *status* da análise e data de criação. A interface também oferece filtros por nível e por *status*, o que facilita a separação entre registros pendentes, aprovados e rejeitados.

Na Figura 6, o marcador I indica o menu de navegação do painel, por meio do qual o gestor acessa as demais áreas do sistema. O marcador II identifica o título da página, responsável por indicar que a tela corresponde à análise de alagamentos. O marcador III destaca os filtros disponíveis, usados para refinar a listagem conforme o nível do alagamento ou o *status* do relato. O marcador IV aponta a coluna de endereço, que também exibe o identificador do registro. O marcador V indica o nível informado para o alagamento, enquanto o marcador VI mostra o *status* atual da análise. O marcador VII apresenta a data e o horário de criação do relato. Por fim, o marcador VIII identifica as ações disponíveis para cada item, permitindo visualizar os detalhes do registro ou acessar sua localização no mapa.

Figura 6 – Tela de listagem dos relatos no painel administrativo.



IV ENDEREÇO	V NÍVEL	VI STATUS	VII DATA	VIII AÇÕES
Avenida Washington Soares, 1321 - Edson Queiroz ID: 1	Leve	Rejeitado	23/05/2026, 13:41	
Avenida Beira Mar, proximo ao Mercado dos Peixes ID: 2	Leve	Pendente	23/05/2026, 13:41	
Rua Monsenhor Bruno, 1153 - Aldeota ID: 3	Moderado	Pendente	23/05/2026, 13:41	
Rua Desembargador Moreira, 2800 - Dionisio Torres ID: 4	Moderado	Pendente	23/05/2026, 13:41	
Avenida Aguanambi, 1600 - Fatima ID: 5	Interditado	Aprovado	23/05/2026, 13:41	

Fonte: Elaborado pela autora.

Ao selecionar um relato na listagem, o gestor é direcionado para uma página com as informações detalhadas daquele registro. Essa visualização reúne os dados enviados pelo usuário e os elementos necessários para a conferência manual. A tela apresenta a imagem cadastrada, o endereço, as coordenadas geográficas, o nível do alagamento, a data de criação e o *status* atual. A partir dessas informações, o gestor pode avaliar se o relato está coerente com a proposta do sistema.

Na Figura 7, o marcador I indica o título da página de análise. O marcador II destaca a imagem enviada pelo usuário, que serve como principal evidência visual do relato. O marcador III agrupa as informações de localização e classificação, incluindo endereço, coordenadas, nível, *status* e data de criação. O marcador IV corresponde à situação do registro, indicando se ele está ativo no sistema. O marcador V apresenta a área de análise automática por IA, utilizada como apoio à decisão do gestor. Essa área exibe a estimativa de confiabilidade e os critérios observados na verificação, como compatibilidade da imagem com alagamento, validade dos metadados e coerência da localização. O marcador VI identifica o campo de comentário do gestor, utilizado para registrar observações internas sobre a decisão tomada. O marcador VII indica os botões de decisão, pelos quais o gestor pode aprovar ou rejeitar o relato após a conferência das informações apresentadas.

Figura 7 – Tela de detalhes de um relato no painel administrativo.

Fonte: Elaborado pela autora.

A análise automática por IA foi incluída como recurso auxiliar no processo de triagem. Ela não substitui a validação manual, mas oferece informações adicionais para apoiar a decisão do gestor. O sistema apresenta uma estimativa de confiabilidade e sinaliza possíveis inconsistências, como imagem incompatível com alagamento, metadados ausentes ou divergência entre a localização do usuário e o endereço informado.

Esse recurso é especialmente útil quando há grande volume de relatos pendentes. A análise automática pode destacar registros com maior probabilidade de validade e indicar casos que exigem maior atenção. Ainda assim, a decisão final permanece sob responsabilidade do gestor, que deve aprovar ou rejeitar o relato com base no conjunto de informações disponíveis.

Após a aprovação, o relato fica disponível para exibição no aplicativo. Quando rejeitado, ele não é apresentado entre as áreas alagadas visíveis ao público. Esse fluxo de validação busca aumentar a confiabilidade das informações exibidas aos usuários e reduzir a presença de registros falsos, duplicados, incompletos ou inadequados.

5 Experimentação e avaliação dos modelos de IA

Para avaliar a possibilidade de uso de IA na triagem de imagens enviadas pelos usuários, foi realizada uma experimentação com diferentes modelos multimodais. O objetivo foi comparar o desempenho desses modelos na identificação de imagens de áreas alagadas e na detecção de imagens suspeitas, inválidas ou manipuladas.

A base utilizada nos testes tem 336 imagens, das quais **30 foram classificadas como fraudadas ou manipuladas**. As imagens foram coletadas a partir de redes sociais, portais de notícias e buscas no Google. Essa escolha buscou aproximar o experimento de um cenário de uso real, no qual usuários podem enviar imagens com diferentes níveis de qualidade, enquadramento, contexto e origem.

A avaliação humana foi utilizada como referência para a comparação com as respostas dos modelos. Essa análise indicou se cada imagem deveria ou não ser considerada válida para o aplicativo. A partir dessa referência, foi possível verificar se a decisão produzida pela IA estava correta.

A escolha dos modelos considerou três critérios principais: suporte à análise multimodal, possibilidade de execução local e diversidade de tamanhos. Como o experimento buscou avaliar a triagem automática de imagens enviadas ao aplicativo, foram selecionados modelos capazes de interpretar entradas visuais e textuais. Também foi priorizado o uso de modelos que pudessem ser executados localmente no LM Studio⁹, pois essa condição permite observar a viabilidade da solução sem depender de serviços externos de IA. A seleção incluiu modelos de diferentes famílias e quantidades aproximadas de parâmetros, variando de versões menores, com menor custo computacional, até modelos maiores, com maior capacidade esperada de análise. Essa variação permitiu comparar não apenas a qualidade das classificações, mas também o tempo de resposta e o consumo de *tokens*. Foram avaliados os modelos *ministral-3-3b*, *qwen3-vl-4b*, *gemma-4-e4b*, *qwen2.5-vl-7b*, *qwen3-vl-8b*, *qwen3.5-9b*, *glm-4.6v-flash*, *gemma-4-26b-a4b*, *qwen3.6-27b*, *qwen3-vl-30b*, *nemotron-3-nano-omni*, *gemma-4-31b* e *qwen3.6-35b-a3b*.

⁹ O LM Studio é uma aplicação para executar modelos de linguagem localmente no computador do usuário, permitindo carregar modelos como Qwen, Gemma e outros em *hardware* próprio. Disponível em: <<https://lmstudio.ai/>>. Acesso em: 23 maio 2026.

Os testes foram executados localmente com o uso do LM Studio. Os resultados retornados pelos modelos foram exportados em arquivos CSV e processados com *scripts* em Python. Esse processamento permitiu organizar as respostas, comparar os resultados da IA com a avaliação humana e calcular as métricas de classificação e desempenho computacional.

5.1 Procedimento metodológico da experimentação

A experimentação foi conduzida em cinco etapas, descritas a seguir para permitir a replicação do processo.

1. **Coleta das imagens:** foram reunidas imagens relacionadas a alagamentos urbanos e imagens inadequadas. A base incluiu imagens obtidas em redes sociais, portais de notícias e buscas no Google. Também foram incluídas imagens classificadas como fraudadas, manipuladas, inválidas ou sem evidência de alagamento urbano.
2. **Avaliação humana das imagens:** após a coleta, as imagens foram analisadas manualmente. Essa avaliação verificou se a imagem era uma fotografia válida, se apresentava alagamento urbano e se havia indícios de fraude, manipulação ou inadequação. O resultado humano foi utilizado como fonte de verdade para a comparação com os modelos de IA.
3. **Execução dos modelos com LM Studio:** foi desenvolvido um *script* em Python para enviar as imagens aos modelos multimodais executados localmente no LM Studio. O *script* realizou a leitura das imagens, enviou cada arquivo ao modelo com o *prompt* correspondente e armazenou a resposta retornada pela IA. O código utilizado nessa etapa está disponível na nota de rodapé¹⁰.
4. **Organização dos resultados:** as respostas dos modelos foram registradas em arquivos *Comma-Separated Values* (CSV). Esses arquivos continham informações como nome da imagem, modelo utilizado, *prompt* aplicado, detecção de alagamento, nível estimado, suspeita de fraude, justificativa da resposta e eventuais erros de execução. Os resultados consolidados da experimentação foram organizados em uma planilha de resultados¹¹.
5. **Cálculo das métricas:** a avaliação humana foi usada como referência para analisar os resultados gerados pela IA. Com base nessa comparação, foram obtidas as métricas de acurácia, precisão, *recall* e *F1-score*. Além disso, foram levantados dados relacionados ao desempenho computacional, como média e desvio padrão dos *tokens* utilizados, tempo médio de resposta e variação desse tempo.

¹⁰ <<https://github.com/ryanemelo/tcc-experimentation/blob/main/script.py>>

¹¹ <<https://docs.google.com/spreadsheets/d/1BhmBNY4ExtB7mnOMdRddRjbYjo89CMGgr0U11BfWvGU/edit?gid=1642662525#gid=1642662525>>

5.2 *Prompts* utilizados

Além da comparação entre modelos, o experimento avaliou o impacto do nível de detalhamento dos *prompts*. Para isso, foram utilizadas três versões de instruções: `full_prompt`, `medium_prompt` e `minimal_prompt`. As três versões tinham o mesmo objetivo: orientar o modelo a analisar se a imagem mostrava um alagamento urbano real e se poderia ser considerada válida para o aplicativo. A diferença estava no nível de detalhamento das instruções. O `full_prompt` apresentou a versão mais completa, com critérios sobre autenticidade, manipulação, imagens geradas por IA, presença de alagamento, nível da água e consistência física da cena. O `medium_prompt` manteve as principais regras de decisão, mas com menor detalhamento. O `minimal_prompt` concentrou apenas as regras essenciais de classificação.

Essa variação permitiu observar se instruções mais detalhadas melhoravam a resposta dos modelos ou se *prompts* mais curtos eram suficientes para a tarefa proposta. Os *prompts* completos estão nos apêndices: `full_prompt` no Apêndice 1, `medium_prompt` no Apêndice 2 e `minimal_prompt` no Apêndice 3.

5.3 Critérios de avaliação

A avaliação foi realizada pela comparação entre a decisão retornada pelo modelo e a classificação humana. Para isso, foram utilizadas as colunas `LLM_result` e `human_result`. A coluna `LLM_result` representa a decisão da IA sobre a imagem. Quando o valor é `true`, a imagem foi considerada válida para o aplicativo. Quando o valor é `false`, a imagem foi classificada como suspeita, fraudada, inválida ou inadequada. A coluna `human_result` representa a decisão humana. Essa coluna foi usada como fonte de verdade para verificar se a resposta da IA estava correta. A partir dessas duas colunas, foi construída uma matriz de confusão para cada combinação de modelo e *prompt*. A avaliação humana foi considerada como o valor real, enquanto a resposta do modelo foi tratada como a predição.

No contexto da aplicação, os erros possuem impactos diferentes. Um falso positivo ocorre quando uma imagem inadequada é aceita pelo modelo. Esse caso é mais crítico, pois permitiria a entrada de uma imagem inválida no aplicativo. Um falso negativo ocorre quando uma imagem válida é rejeitada. Esse erro também prejudica o sistema, pois impede o aproveitamento de uma contribuição do usuário.

Além das métricas de classificação, a análise considerou o desempenho computacional dos modelos. Para isso, foram levantados a média e o desvio padrão dos *tokens* utilizados, e o tempo médio de resposta e sua variação. Esses dados ajudaram a observar, junto com a qualidade das classificações, o custo de cada modelo.

A Tabela 8 reúne os resultados da experimentação, separados por *prompt* e modelo. As colunas de acurácia, precisão, *recall* e *F1-score* receberam uma escala gradual em tons de azul para facilitar a comparação visual. Nessa escala, valores menores aparecem em tons mais claros, enquanto os maiores são representados por tons mais escuros. O recurso é apenas visual e serve para destacar as diferenças de desempenho entre os modelos e *prompts* avaliados.

Tabela 8 – Resultado da experimentação por *prompt* e modelo.

<i>Prompt</i>	Informações do modelo			Análise				Desempenho			
	Família	Modelo	Tam.	Acurácia	Precisão	Recall	F1 score	Tokens média	Tokens stdev	Tempo médio (s)	Tempo stdev (s)
full_prompt	Ministral	ministral-3-3b	3B	81.5%	97.7%	81.7%	89.0%	2263.3	99.0	6.6	1.0
	Qwen	qwen3-v1-4b	4B	98.5%	98.7%	99.7%	99.2%	2176.0	67.7	6.4	1.5
	Gemma	gemma-4-e4b	4B	90.5%	97.9%	91.5%	94.6%	1948.0	5.0	9.5	1.0
	Qwen	qwen2.5-v1-7b	7B	89.6%	97.9%	90.5%	94.1%	2278.2	96.7	7.9	1.2
	Qwen	qwen3-v1-8b	8B	97.3%	98.7%	98.4%	98.5%	2166.1	68.1	7.6	1.7
	Qwen	qwen3.5-9b	9B	97.6%	99.3%	98.0%	98.7%	2057.3	68.6	11.1	1.1
	GLM	glm-4.6v-flash	9B	93.2%	95.5%	97.1%	96.3%	2225.1	96.8	7.8	1.4
	Gemma	gemma-4-26b-a4b	26B	81.8%	97.7%	82.0%	89.2%	1945.6	8.2	10.0	2.6
	Qwen	qwen3.6-27b	27B	95.2%	98.7%	96.1%	97.4%	2063.6	67.9	22.2	2.8
	Qwen	qwen3-v1-30b	30B	97.0%	97.7%	99.0%	98.4%	2170.5	68.0	16.2	1.2
	Nemotron	nemotron-3-nano-omni	30B	91.1%	98.3%	91.8%	94.9%	2013.5	6.2	25.2	2.4
	Gemma	gemma-4-31b	31B	94.9%	99.0%	95.4%	97.2%	1955.5	13.0	28.4	3.1
	Qwen	qwen3.6-35b-a3b	35B	96.1%	99.0%	96.7%	97.9%	2062.4	68.4	17.2	1.7
medium_prompt	Ministral	ministral-3-3b	3B	88.7%	97.9%	89.5%	93.5%	1588.1	98.5	5.8	0.9
	Qwen	qwen3-v1-4b	4B	97.6%	98.1%	99.3%	98.7%	1468.4	67.6	5.6	1.2
	Gemma	gemma-4-e4b	4B	90.8%	97.6%	92.2%	94.8%	1329.1	5.5	9.4	0.8
	Qwen	qwen2.5-v1-7b	7B	91.7%	97.6%	93.1%	95.3%	1579.0	96.5	7.8	1.1
	Qwen	qwen3-v1-8b	8B	96.7%	97.4%	99.0%	98.2%	1459.6	68.2	7.4	1.3
	Qwen	qwen3.5-9b	9B	97.0%	99.3%	97.4%	98.3%	1441.4	67.8	10.6	0.9
	GLM	glm-4.6v-flash	9B	93.8%	94.7%	98.7%	96.6%	1527.6	96.7	7.9	1.1
	Gemma	gemma-4-26b-a4b	26B	94.0%	97.4%	96.1%	96.7%	1331.4	15.5	10.1	5.5
	Qwen	qwen3.6-27b	27B	96.1%	98.7%	97.1%	97.9%	1446.7	67.8	21.0	2.4
	Qwen	qwen3-v1-30b	30B	95.8%	96.5%	99.0%	97.7%	1469.1	67.8	12.1	1.1
	Nemotron	nemotron-3-nano-omni	30B	92.6%	98.6%	93.1%	95.8%	1339.0	3.7	23.7	1.7
	Gemma	gemma-4-31b	31B	95.8%	99.0%	96.4%	97.7%	1347.8	10.0	28.8	2.5
	Qwen	qwen3.6-35b-a3b	35B	95.5%	99.3%	95.8%	97.5%	1449.6	67.6	16.1	1.6
minimal_prompt	Ministral	ministral-3-3b	3B	90.8%	95.7%	94.1%	94.9%	1390.3	98.3	5.8	0.8
	Qwen	qwen3-v1-4b	4B	95.2%	98.0%	96.7%	97.4%	1281.2	67.6	5.1	1.0
	Gemma	gemma-4-e4b	4B	90.2%	95.7%	93.5%	94.5%	1159.7	5.0	9.1	0.8
	Qwen	qwen2.5-v1-7b	7B	95.5%	96.2%	99.0%	97.6%	1383.5	96.6	7.5	0.9
	Qwen	qwen3-v1-8b	8B	95.5%	97.4%	97.7%	97.6%	1274.0	68.1	6.8	1.1
	Qwen	qwen3.5-9b	9B	97.6%	98.1%	99.3%	98.7%	1273.0	67.9	10.5	0.9
	GLM	glm-4.6v-flash	9B	91.7%	92.1%	99.3%	95.6%	1347.8	96.7	7.3	1.1
	Gemma	gemma-4-26b-a4b	26B	92.3%	97.0%	94.4%	95.7%	1179.0	44.3	16.3	17.7
	Qwen	qwen3.6-27b	27B	94.9%	98.7%	95.8%	97.2%	1276.3	67.8	20.8	2.3
	Qwen	qwen3-v1-30b	30B	95.2%	96.5%	98.4%	97.4%	1281.2	67.5	10.4	0.8
	Nemotron	nemotron-3-nano-omni	30B	92.6%	96.1%	95.8%	95.9%	1146.1	4.1	23.7	1.6
	Gemma	gemma-4-31b	31B	95.2%	99.3%	95.4%	97.3%	1170.1	13.1	26.2	2.7
	Qwen	qwen3.6-35b-a3b	35B	95.8%	99.0%	96.4%	97.7%	1279.0	68.6	15.6	1.4

70–80% 80–90% 90–92% 92–94% 94–96% 96–98% 98–100%

5.4 Análises

Esta seção compara os modelos de IA a partir de diferentes critérios. Primeiro, a análise considerou os *prompts* utilizados, comparando se instruções mais completas trouxeram ganho nos resultados ou se apenas aumentaram o consumo de *tokens*. Depois, foi analisado o tamanho aproximado dos modelos, para verificar se modelos com mais parâmetros apresentaram resultados superiores.


Na sequência, foram observados os dados de performance e tempo de execução, já que a proposta do aplicativo depende de uma triagem que possa ser usada no fluxo de validação dos relatos enviados pelos usuários. Em seguida, foram comparadas as métricas de acurácia, precisão, *recall* e *F1-score*, usadas para verificar quais modelos tiveram melhor desempenho na classificação das imagens.

Por fim, foram discutidos os falsos positivos e falsos negativos, pois aceitar uma imagem inadequada ou rejeitar uma imagem válida afeta a confiabilidade do sistema de maneiras diferentes. Assim, a avaliação não se concentrou apenas no modelo com maior valor numérico nas métricas. Também foram considerados fatores práticos para o uso da IA no sistema, como consumo de *tokens*, tempo de resposta e impacto dos erros de classificação no monitoramento colaborativo de áreas alagadas.

5.4.1 Análise por *prompt*

A análise por *prompt* teve como objetivo verificar se o nível de detalhamento da instrução fornecida aos modelos influenciou o desempenho na classificação das imagens. Para isso, foram comparadas três variações de *prompt*: *minimal*, *medium* e *full*. A comparação considerou principalmente o *F1-score* médio, por ser uma métrica adequada para avaliar o equilíbrio entre precisão e *recall*, além do consumo médio de *tokens*, que indica o custo computacional associado a cada configuração. A Figura 8 apresenta a relação entre essas duas medidas para cada variação de *prompt*.

Figura 8 – Relação entre *F1-score* médio e consumo médio de *tokens* por *prompt*. As barras de erro indicam o desvio padrão.



Fonte: Elaborado pela autora.

Os resultados mostram que o aumento do detalhamento do *prompt* não levou, necessariamente, a uma melhora no desempenho geral. O *medium* apresentou o maior *F1-score* médio, com 96,8%, seguido de forma muito próxima pelo *minimal*, com 96,7%. A diferença entre esses dois *prompts* foi pequena, de apenas 0,1 ponto percentual, o que indica desempenho praticamente equivalente. Já o *full*, apesar de conter instruções mais completas, apresentou o menor *F1-score* médio entre as três configurações, com 95,8%.

Ao observar o consumo médio de *tokens*, a diferença entre os *prompts* se torna mais evidente. O *full* foi o mais custoso, com média de 2.102 *tokens*, enquanto o *medium* consumiu cerca de 1.444 *tokens* e o *minimal* apresentou o menor consumo, com aproximadamente 1.265 *tokens*. Assim, o *prompt* mais detalhado exigiu maior quantidade de *tokens*, mas não apresentou ganho proporcional de desempenho.

A relação entre *F1-score* e consumo de *tokens* reforça essa interpretação. O *minimal* apresentou o melhor aproveitamento relativo, pois manteve um *F1-score* muito próximo ao melhor resultado geral e, ao mesmo tempo, teve o menor consumo médio de *tokens*. O *medium* obteve o maior *F1-score*, mas com custo um pouco superior. O *full*, por sua vez, concentrou o maior consumo e o menor desempenho médio, indicando que o excesso de instruções pode não ter contribuído para a tarefa avaliada.

Com base nesses resultados, observa-se que *prompts* mais longos não foram necessariamente mais eficazes para a classificação das imagens analisadas. No contexto deste experimento, instruções mais objetivas foram suficientes para orientar os modelos e produzir resultados competitivos. O *medium* se destacou pelo melhor *F1-score* médio, enquanto o *minimal* apresentou melhor relação entre desempenho e consumo de *tokens*. Dessa forma, a escolha do *prompt* deve considerar não apenas a métrica de classificação, mas também o custo de execução, especialmente em cenários nos quais a solução precisa processar muitas imagens.

5.4.2 Análise por tamanho do modelo

Nesta análise, os modelos foram agrupados pelo tamanho aproximado em parâmetros. A comparação considerou *F1-score* médio, acurácia média, tempo médio de execução e consumo médio de *tokens*. A intenção foi observar se modelos maiores tiveram, de fato, resultados melhores na classificação das imagens.

As médias foram calculadas a partir dos registros individuais apresentados na Tabela 8, agrupados pelo tamanho aproximado dos modelos. Em cada grupo, foram consideradas todas as execuções dos *prompts* realizadas para os modelos daquela faixa. Assim, os valores da Tabela 9 representam o comportamento médio observado em cada grupo de tamanho.

Os dados da Tabela 9 não mostram uma relação direta entre tamanho do modelo e melhora no desempenho. O maior *F1-score* médio apareceu no grupo de 8B parâmetros, com 98,10%. Esse valor ficou acima do obtido por grupos maiores, como 26B, 27B, 30B, 31B e 35B. Nesse conjunto de testes, portanto, ter mais parâmetros não significou necessariamente classificar melhor as imagens.

Tabela 9 – Resumo dos resultados por tamanho aproximado do modelo.

Tamanho	Modelos	<i>F1-score</i> médio (%)	Acurácia média (%)	Tempo médio (s)	<i>Tokens</i> médios
3B	ministral-3-3b	92,47	87,00	6,07	1.747
4B	qwen3-v1-4b; gemma-4-e4b	96,53	93,80	7,52	1.560
7B	qwen2.5-v1-7b	95,67	92,27	7,73	1.747
8B	qwen3-v1-8b	98,10	96,50	7,27	1.633
9B	qwen3.5-9b; glm-4.6v-flash	97,37	95,15	9,20	1.645
26B	gemma-4-26b-a4b	93,87	89,37	12,13	1.485
27B	qwen3.6-27b	97,50	95,40	21,33	1.596
30B	qwen3-v1-30b; nemotron-3-nano-omni	96,68	94,05	18,55	1.570
31B	gemma-4-31b	97,40	95,30	27,80	1.491
35B	qwen3.6-35b-a3b	97,70	95,80	16,30	1.597

Fonte: Elaborado pela autora.

O grupo de 3B parâmetros teve os menores valores, com *F1-score* médio de 92,47% e acurácia média de 87,00%. Esse resultado indica uma limitação maior nos modelos menores para a tarefa proposta. A partir do grupo de 4B parâmetros, já houve melhora, com *F1-score* médio de 96,53%. Mesmo assim, o crescimento do desempenho não acompanhou o aumento do tamanho de forma contínua.

Os grupos de 8B e 9B parâmetros ficaram entre os resultados mais equilibrados. O grupo de 8B alcançou *F1-score* médio de 98,10% e tempo médio de 7,27 segundos. O grupo de 9B também teve bom desempenho, com *F1-score* médio de 97,37% e tempo médio de 9,20 segundos. Em comparação, grupos maiores, como 27B, 30B e 31B, registraram tempos médios de 21,33 segundos, 18,55 segundos e 27,80 segundos. Assim, os modelos intermediários entregaram bons resultados sem o mesmo aumento no tempo de execução.

Entre os modelos maiores, o comportamento foi menos uniforme. O grupo de 35B parâmetros teve *F1-score* médio de 97,70%, valor próximo aos melhores resultados, mas com tempo médio de 16,30 segundos. O grupo de 31B também apresentou *F1-score* alto, com 97,40%, porém registrou o maior tempo médio da tabela, com 27,80 segundos. Já o grupo de 26B ficou abaixo dos demais modelos grandes, com *F1-score* médio de 93,87%, mesmo tendo mais parâmetros que os grupos intermediários.

O consumo médio de *tokens* também não seguiu uma ordem clara conforme o tamanho do modelo. O menor consumo apareceu no grupo de 26B parâmetros, com 1.485 *tokens*. Por outro lado, o grupo de 3B ficou entre os maiores consumos, com 1.747 *tokens*. Nesse caso, a quantidade de *tokens* parece estar mais ligada ao tipo de resposta gerada por cada modelo do que ao número aproximado de parâmetros.

Pelos resultados obtidos, não é possível concluir que os modelos maiores foram sempre melhores. O aumento do tamanho apareceu mais claramente no tempo de execução do que nas métricas de classificação. Para esta tarefa, os grupos de 8B e 9B parâmetros tiveram uma relação mais favorável entre *F1-score*, acurácia, tempo de resposta e consumo de *tokens*. Por isso, a escolha do modelo deve considerar tanto a qualidade da classificação quanto o custo necessário para executar a solução.


5.4.3 Análise do tempo de execução

Nesta etapa, foi analisado o tempo médio que cada modelo levou para classificar as imagens. Diferente das análises anteriores, que consideraram métricas de classificação, como acurácia, precisão, *recall* e *F1-score*, esta seção trata apenas do custo temporal da execução. Assim, o foco está em verificar quais modelos responderam mais rapidamente.

Esse aspecto é relevante para a proposta do aplicativo, pois a análise deve apoiar a validação dos relatos sem tornar o processo excessivamente lento. Em um cenário de uso pela comunidade, tempos menores podem favorecer uma triagem mais ágil, especialmente quando houver maior volume de registros enviados ao sistema.

Conforme apresentado na Figura 9, o menor tempo médio foi registrado pelo **qwen3-vl-4b**, com 5,70 segundos. Em seguida aparecem o **ministral-3-3b**, com 6,07 segundos, e o **qwen3-vl-8b**, com 7,27 segundos. Esses três modelos formaram o grupo com menor tempo de execução na avaliação, o que pode ser vantajoso em situações nas quais os relatos precisam ser analisados com maior agilidade.

Figura 9 – Tempo médio de execução por modelo. As barras de erro horizontais indicam o desvio padrão.



Fonte: Elaborado pela autora.

Também ficaram abaixo de 10 segundos o `glm-4.6v-flash`, o `qwen2.5-v1-7b` e o `gemma-4-e4b`, com tempos médios de 7,67 segundos, 7,73 segundos e 9,33 segundos, respectivamente. Esses resultados indicam que parte dos modelos menores e intermediários conseguiu processar as imagens em menos de 10 segundos.

A partir do `qwen3.5-9b`, os tempos médios passaram a ser mais elevados. Esse modelo apresentou média de 10,73 segundos. Na sequência, aparecem o `gemma-4-26b-a4b`, com 12,13 segundos, e o `qwen3-v1-30b`, com 12,90 segundos. Embora esses valores ainda possam ser aceitáveis, eles representam um aumento em relação aos modelos mais rápidos.

Os maiores tempos foram observados no `qwen3.6-35b-a3b`, no `qwen3.6-27b`, no `nemotron-3-nano-omni` e no `gemma-4-31b`. O `qwen3.6-35b-a3b` teve média de 16,30 segundos, enquanto o `qwen3.6-27b` chegou a 21,33 segundos. Os valores mais altos foram registrados pelo `nemotron-3-nano-omni`, com 24,20 segundos, e pelo `gemma-4-31b`, com 27,80 segundos. Em um cenário com muitos relatos enviados pela comunidade, tempos dessa ordem podem dificultar uma análise mais próxima do tempo real.

Considerando apenas o tempo médio de execução, o `qwen3-v1-4b` foi o modelo mais rápido entre os avaliados. O `ministral-3-3b` e o `qwen3-v1-8b` também apresentaram resultados favoráveis nesse critério. Já modelos como o `gemma-4-31b`, o `nemotron-3-nano-omni` e o `qwen3.6-27b` foram menos adequados para cenários que exigem resposta mais rápida. Para a proposta do aplicativo, modelos com menor tempo médio de execução tendem a apoiar melhor a triagem das imagens sem prejudicar o andamento da validação.


5.4.4 Análise comparativa por modelo

A análise comparativa por modelo teve como objetivo observar o comportamento médio dos modelos avaliados, considerando as execuções realizadas com os três *prompts*. Diferente da análise por *prompt*, esta etapa não busca verificar apenas qual configuração de instrução produziu o melhor resultado. O foco está em comparar os modelos entre si, considerando a relação entre acurácia, precisão, *recall*, *F1-score*, tempo de resposta e consumo médio de *tokens*.

Os resultados indicam que os modelos da família **Qwen** apresentaram o desempenho mais consistente na tarefa proposta. O `qwen3.5-9b` obteve o maior *F1-score* médio, com 98,57%, e também a maior acurácia média, com 97,40%. O `qwen3-v1-4b` ficou muito próximo, com *F1-score* médio de 98,43% e acurácia média de 97,10%. Essa diferença pequena mostra que, para a triagem de imagens deste experimento, o aumento de tamanho do modelo não resultou necessariamente em ganho proporcional de desempenho. Mesmo sendo menor, o `qwen3-v1-4b` apresentou resultado competitivo e respondeu em menor tempo médio.

Esse comportamento é relevante para a proposta do sistema. Como a IA foi pensada como apoio à análise dos relatos no painel administrativo, o modelo escolhido não precisa ser apenas o de maior métrica isolada. Ele também precisa responder em tempo adequado e manter boa capacidade de distinguir imagens válidas

Figura 10 – Comparação entre precisão e *recall* médios por modelo.



Fonte: Elaborado pela autora.

de imagens inadequadas. Nesse ponto, o **qwen3-v1-4b** se destaca por combinar alto *F1-score*, alta acurácia e o menor tempo médio entre os modelos com desempenho superior a 98% de *F1-score*. O **qwen3.5-9b**, embora tenha apresentado o melhor resultado geral nas métricas de classificação, teve tempo médio maior.

A comparação também mostra diferenças importantes entre precisão e *recall*. Modelos como **qwen3-v1-30b** e **glm-4.6v-flash** apresentaram *recall* elevado, indicando maior tendência a reconhecer imagens válidas. Esse comportamento reduz a chance de rejeitar uma contribuição real do usuário, mas pode aumentar o risco de aceitar imagens inadequadas quando a precisão é menor. No caso do **glm-4.6v-flash**, por exemplo, o *recall* médio foi de 98,37%, enquanto a precisão média ficou em 94,10%. Para o contexto do aplicativo, essa diferença exige atenção, pois falsos positivos podem comprometer a confiabilidade das informações exibidas no mapa.

Por outro lado, modelos como **qwen3.6-35b-a3b** e **gemma-4-31b** apresentaram precisão média elevada, ambos com 99,10%. Esse resultado sugere uma postura mais restritiva ao aceitar imagens como válidas. No entanto, o *recall* desses modelos foi menor do que o observado nos melhores modelos da família **Qwen**. Na prática, isso pode representar menor risco de aceitar registros inadequados, mas maior possibilidade de rejeitar imagens que seriam úteis para o monitoramento colaborativo.

Esse equilíbrio é importante porque, no sistema proposto, tanto a aceitação indevida quanto a rejeição indevida afetam a qualidade do fluxo de validação.

Os modelos com menor desempenho médio apresentaram limitações diferentes. O `ministral-3-3b` teve o menor *F1-score* médio, com 92,47%, e o menor *recall*, com 88,43%. Isso indica dificuldade maior em recuperar corretamente as imagens válidas. O `gemma-4-e4b` e o `gemma-4-26b-a4b` também ficaram abaixo dos modelos mais bem avaliados, mesmo pertencendo a faixas de tamanho diferentes. Esse resultado reforça que o número aproximado de parâmetros não explica, sozinho, o desempenho observado.

Entre os modelos maiores, o comportamento foi heterogêneo. O `qwen3-v1-30b` manteve desempenho elevado, com *F1-score* médio de 97,83%, mas não superou os modelos `qwen3-v1-4b`, `qwen3-v1-8b` e `qwen3.5-9b`. O `nemotron-3-nano-omni`, também classificado na faixa de 30B, apresentou *F1-score* médio de 95,53% e tempo médio de 24,20 segundos. Essa comparação mostra que modelos com tamanho semelhante podem ter resultados bastante distintos, possivelmente em razão de diferenças de arquitetura, treinamento e forma de resposta à tarefa proposta.

A análise por modelo permite observar que a melhor escolha para integração ao sistema não depende apenas da maior pontuação final. O `qwen3.5-9b` apresentou o melhor desempenho médio em *F1-score* e acurácia, enquanto o `qwen3-v1-4b` ofereceu a relação mais favorável entre qualidade da classificação e tempo de resposta. Para uma aplicação de triagem automatizada, essa relação é especialmente importante, pois o modelo deve apoiar a revisão dos relatos sem tornar o processo excessivamente lento. Assim, os resultados indicam que modelos intermediários e menores podem ser mais adequados ao cenário proposto do que modelos maiores, desde que mantenham desempenho próximo aos melhores resultados observados.

5.4.5 Análise de impacto dos falsos positivos e falsos negativos

A análise de falsos positivos e falsos negativos foi realizada para identificar os principais erros cometidos pelos modelos e compreender seus impactos no uso do aplicativo. No processo de triagem das imagens enviadas pela comunidade, esses erros não possuem o mesmo peso prático. Aceitar uma imagem inválida pode comprometer a confiabilidade do mapa, enquanto rejeitar uma imagem válida pode impedir que uma situação real de alagamento seja registrada.

Neste experimento, considerou-se como verdadeiro positivo o caso em que o modelo aceitou corretamente uma imagem válida de alagamento urbano. O verdadeiro negativo ocorreu quando o modelo rejeitou corretamente uma imagem inválida, suspeita, fraudada, manipulada ou inadequada. O falso positivo correspondeu aos casos em que o modelo aceitou uma imagem que deveria ser rejeitada. O falso negativo, por sua vez, ocorreu quando o modelo rejeitou uma imagem válida de alagamento. A Tabela 10 reúne essas definições e apresenta os possíveis impactos de cada resultado no funcionamento do aplicativo.

Tabela 10 – Interpretação dos erros no contexto da triagem de imagens.

Tipo de resultado	Interpretação no experimento	Possível impacto no aplicativo
Verdadeiro positivo	O modelo aceita corretamente uma imagem válida de alagamento.	O relato pode seguir para aprovação ou exibição, contribuindo para o monitoramento da área afetada.
Verdadeiro negativo	O modelo rejeita corretamente uma imagem inválida, suspeita ou inadequada.	O sistema evita que imagens sem valor comprobatório sejam usadas no mapa colaborativo.
Falso positivo	O modelo aceita uma imagem inválida, fraudada, manipulada, irrelevante ou sem alagamento.	O mapa pode exibir uma informação incorreta, reduzindo a confiança dos usuários e dificultando a interpretação da situação real.
Falso negativo	O modelo rejeita uma imagem válida de alagamento.	Um relato real pode deixar de ser considerado, reduzindo a cobertura do monitoramento colaborativo.

Fonte: Elaborado pela autora.

Os falsos positivos representam um risco direto para a confiabilidade da aplicação. Quando o modelo aceita uma imagem inválida, o sistema pode tratar como evidência um registro que não comprova uma situação real de alagamento. Esse tipo de erro é especialmente sensível porque o aplicativo tem como finalidade apoiar a população durante períodos de chuva intensa. Uma imagem aceita indevidamente pode gerar marcações incorretas no mapa, indicar problemas inexistentes ou dificultar a leitura das áreas realmente afetadas.

Os falsos negativos também são relevantes, mas produzem um efeito diferente. Nesse caso, o modelo rejeita uma imagem que deveria ser aceita. O principal impacto é a perda de um registro válido, o que pode reduzir a quantidade de informações disponíveis para a comunidade e para os administradores do sistema. Em um cenário de monitoramento colaborativo, a rejeição indevida de imagens reais pode limitar a representação das áreas alagadas, principalmente quando há poucos relatos sobre determinada região.

A comparação entre esses dois tipos de erro mostra que a escolha do modelo não deve considerar apenas o desempenho geral. Para a proposta deste trabalho, o falso positivo tende a ser mais crítico quando o objetivo principal é impedir que imagens inadequadas sejam exibidas à comunidade. Já o falso negativo se torna mais preocupante quando a prioridade é não perder registros reais de alagamento. Assim, a definição do modelo mais adequado depende do grau de rigor desejado na triagem.

No contexto do aplicativo, uma estratégia mais conservadora pode ser adequada para reduzir falsos positivos. Nesse caso, imagens suspeitas ou com baixa evidência visual de alagamento poderiam ser encaminhadas para revisão no painel administrativo, em vez de serem aprovadas automaticamente. Essa abordagem preserva a função da IA como apoio à triagem, sem transferir totalmente ao modelo a responsabilidade pela decisão final.

A análise dos falsos negativos indica a necessidade de cuidado com imagens reais que apresentam baixa qualidade, pouca iluminação, enquadramento limitado

ou sinais visuais menos evidentes de alagamento. Esses casos podem dificultar a interpretação do modelo e levar à rejeição indevida. Por isso, mesmo quando a IA classifica uma imagem como inválida, a aplicação pode manter mecanismos de revisão humana para casos incertos, especialmente quando o relato contém localização e descrição compatíveis com uma ocorrência real.

Com base nessa interpretação, os erros de classificação devem ser avaliados de acordo com o impacto esperado no uso do sistema. Os falsos positivos afetam principalmente a confiabilidade das informações disponibilizadas no mapa. Os falsos negativos afetam a capacidade do aplicativo de representar todos os pontos reais de alagamento informados pela comunidade. Dessa forma, a triagem automatizada deve ser entendida como um recurso de apoio, e não como substituição completa da validação humana. Essa decisão é coerente com a proposta do sistema, em que os registros enviados pelos usuários passam por análise antes de serem disponibilizados à comunidade.

6 Trabalhos Relacionados

Esta seção apresenta os trabalhos relacionados encontrados a partir de uma revisão sistemática da literatura. A busca considerou artigos sobre alagamentos, enchentes e inundações que apresentassem alguma solução tecnológica. A organização da seção segue quatro partes: planejamento, execução, resultados e síntese das questões de pesquisa. No planejamento, são descritos o método adotado, as questões de pesquisa, a estratégia de busca, a *string* utilizada e os critérios de inclusão. Na execução, são informados os dados da busca, a remoção de duplicados e a triagem dos artigos. Nos resultados, são apresentados os estudos selecionados e discutidos os trabalhos com texto completo acessado. Ao final, são retomadas as questões de pesquisa.

6.1 Planejamento

A revisão sistemática da literatura foi organizada com base em [Kitchenham et al. \(2009\)](#). As diretrizes dos autores foram usadas para estruturar a busca, a seleção e a análise dos artigos. Com isso, os critérios foram definidos antes da triagem, evitando que a escolha dos trabalhos dependesse apenas de decisões tomadas durante a leitura.

Nesta pesquisa, a revisão buscou estudos sobre soluções tecnológicas aplicadas a alagamentos, enchentes e inundações. O interesse principal foi identificar trabalhos próximos ao aplicativo proposto, sobretudo aqueles que tratam de coleta por usuários, uso de imagens, localização geográfica, sistemas móveis, sistemas *web*, sensores ou IA.

As questões de pesquisa usadas para orientar a revisão foram:

- **QP1:** Que tipos de soluções tecnológicas têm sido propostas para apoiar o monitoramento, a detecção, o mapeamento ou a análise de alagamentos, enchentes e inundações urbanas?
- **QP2:** Quais recursos são utilizados nessas soluções?
- **QP3:** Quais aspectos dos trabalhos relacionados encontrados se aproximam ou se diferenciam da proposta deste trabalho?

A estratégia de busca indica como a procura pelos estudos foi organizada, ou seja, quais temas, termos e bases foram usados na revisão. Nesta pesquisa, ela foi definida a partir dos temas centrais do trabalho: alagamentos, participação cidadã, aplicações móveis e IA. Com esses termos, foi montada uma *string* de busca, que corresponde à expressão usada para pesquisar nas bases científicas. Essa expressão combina palavras-chave com operadores booleanos, como *AND* e *OR*, para aproximar os resultados do tema investigado. A *string* de busca utilizada foi:

```
("flood" OR "flooding" OR "inundation")
AND
("mobile app")
AND
("citizen participation" OR "collaborative monitoring"
OR "collaborative" OR "participatory"
OR "citizen science")
AND
("artificial intelligence" OR "machine learning"
OR "deep learning" OR "computer vision"
OR "AI" OR "ML")
```

A escolha dos estudos seguiu os critérios de inclusão da Tabela 11. Esses critérios definem o que um artigo precisava apresentar para continuar na revisão. Com isso, a triagem ficou mais objetiva e limitada aos trabalhos relacionados ao tema da pesquisa.

Tabela 11 – Critérios de inclusão.

Código	Descrição
CI1	O estudo deve abordar alagamentos, enchentes ou inundações em contexto urbano.
CI2	O estudo deve apresentar uma solução tecnológica voltada ao monitoramento, detecção, mapeamento ou análise desses eventos.
CI3	O estudo deve envolver pelo menos um dos seguintes recursos: aplicativo móvel, sistema <i>web</i> , geolocalização, sensores, participação colaborativa de usuários ou IA.

Fonte: Elaborado pela autora.

Foram excluídos estudos duplicados, trabalhos sem relação com alagamentos, enchentes ou inundações e publicações que não apresentavam uma solução tecnológica alinhada ao escopo desta pesquisa.

6.2 Execução

A busca foi realizada nas bases IEEE Xplore¹², ACM Digital Library¹³ e Springer Nature¹⁴. Os registros da triagem foram organizados em uma planilha pública¹⁵.

A aplicação da *string* de busca retornou inicialmente 282 estudos. Após a remoção dos registros duplicados, permaneceram 272 artigos para análise. Desse total, 2 foram obtidos na IEEE Xplore, 20 na ACM Digital Library e 250 na Springer Nature. Em seguida, foi feita a leitura do título, do resumo e das palavras-chave. Nessa etapa, cada estudo foi comparado aos critérios definidos no planejamento. Dos 12 estudos selecionados, cinco tiveram o texto completo acessado. Os demais não foram analisados em profundidade porque o conteúdo integral não foi obtido durante a revisão. A Tabela 12 apresenta um resumo do processo de seleção.

Tabela 12 – Resumo da execução da revisão sistemática.

Etapa	Quantidade
Estudos retornados na busca inicial	282
Estudos após remoção de duplicados	272
Estudos da IEEE Xplore	2
Estudos da ACM Digital Library	20
Estudos da Springer Nature	250
Estudos excluídos após análise de título, resumo e palavras-chave	260
Estudos selecionados para análise	12
Estudos com texto completo acessado	5

Fonte: Elaborado pela autora.

6.3 Resultados

Esta subseção apresenta os estudos selecionados na revisão e discute os trabalhos cujo texto completo pôde ser acessado. A análise considera os recursos adotados em cada solução e a relação desses recursos com a proposta desenvolvida neste trabalho. Primeiro, são apresentados os estudos acessados e seus enfoques principais. Em seguida, os trabalhos são comparados em relação ao uso de colaboração cidadã, aplicativo móvel, sistema *web*, mapa, imagens e IA. A Tabela 13 apresenta os estudos selecionados após a leitura do texto completo.

¹² <<https://ieeexplore.ieee.org/>>

¹³ <<https://dl.acm.org/>>

¹⁴ <<https://www.springernature.com/>>

¹⁵ <https://docs.google.com/spreadsheets/d/1TyOspYt4vIaafkHQfct6Ci0mfNGQ83ITU-SU_eQyqH8>

Tabela 13 – Estudos selecionados na revisão sistemática.

Referência	Enfoque do estudo
Narayanan et al. (2014)	Monitoramento de alagamentos urbanos com sensoriamento participativo e visão computacional.
Sulistyo et al. (2025)	Aplicação móvel e <i>web</i> para coleta de dados sobre inundações com apoio de ciência cidadã.
Alizadeh e Behzadan (2023)	Mapeamento de inundação com redes convolucionais profundas e imagens de sinalização urbana.
Ajin et al. (2025)	Mapeamento de risco de inundação em bacia urbana com método multicritério.
Paul, Chauhan e Dutta (2023)	Interpretação de imagens e georreferenciamento com IA e tecnologia geoespacial aberta.

Fonte: Elaborado pela autora.

Os estudos acessados indicam três grupos de abordagem. O primeiro grupo utiliza imagens e visão computacional para estimar o nível ou a profundidade da água. Essa característica aparece em [Narayanan et al. \(2014\)](#) e [Alizadeh e Behzadan \(2023\)](#). O segundo grupo prioriza a coleta colaborativa de dados por meio de aplicativos móveis e sistemas *web*, como em [Sulistyo et al. \(2025\)](#). O terceiro grupo utiliza recursos geoespaciais para análise, armazenamento e visualização de dados, como em [Ajin et al. \(2025\)](#) e [Paul, Chauhan e Dutta \(2023\)](#).

O trabalho de [Narayanan et al. \(2014\)](#) trata do monitoramento de alagamentos urbanos a partir de imagens enviadas por usuários. Os autores combinam sensoriamento participativo e visão computacional para estimar o nível da água em estruturas fixas, como prédios e postes. A análise compara a imagem enviada com uma imagem de referência. Para isso, o algoritmo *Scale-Invariant Feature Transform* (SIFT), proposto por [Lowe \(2004\)](#), é usado na identificação de pontos semelhantes entre as imagens. A partir dessa comparação, a linha da inundação é usada para estimar a altura da água.

O estudo de [Sulistyo et al. \(2025\)](#) propõe uma aplicação móvel e *web* para registrar dados de inundação com apoio de ciência cidadã. O sistema coleta coordenadas geográficas, altura da inundação, duração do evento, observações e imagens. Os dados são armazenados em uma base estruturada e podem ser visualizados em WebGIS¹⁶, ou exportados em CSV. Esse trabalho se aproxima da proposta desta pesquisa pelo uso de participação cidadã, aplicação móvel, sistema *web*, geolocalização e imagens.

Em [Alizadeh e Behzadan \(2023\)](#), as imagens também são usadas para apoiar a análise de inundações urbanas. Os autores investigam o uso de redes convolucionais profundas, abordagem associada ao aprendizado profundo e amplamente utilizada em

¹⁶ O WebGIS corresponde ao uso de Sistemas de Informação Geográfica em ambiente *web*, permitindo a visualização e a consulta de dados espaciais pela internet. Tecnologias desse tipo podem utilizar padrões geoespaciais, como o *Web Map Service* (WMS), definido pelo *Open Geospatial Consortium* (OGC), para solicitar e exibir mapas georreferenciados em aplicações de navegador ([Open Geospatial Consortium, 2026](#)).

tarefas de visão computacional (LECUN; BENGIO; HINTON, 2015), para estimar a profundidade da inundação a partir de placas de trânsito parcialmente submersas. O método detecta placas e postes em imagens antes e depois do evento. A estimativa ocorre pela comparação entre a parte visível da estrutura antes e depois da inundação. Assim como em Narayanan et al. (2014), a imagem é usada para medir a água a partir de objetos presentes na cena.

O trabalho de Ajin et al. (2025) segue outra direção. Os autores apresentam um modelo de mapeamento de risco de inundação em uma bacia urbana na Índia. O estudo utiliza a análise de decisão multicritério, *Multi-Criteria Decision Analysis* (MCDA), combinada ao Processo de Hierarquia Analítica, *Analytic Hierarchy Process* (AHP), método que permite atribuir pesos a diferentes fatores associados ao risco (SAATY, 1980; MALCZEWSKI, 1999). No trabalho analisado, esse método integra fatores de perigo, vulnerabilidade e exposição. Diferente dos estudos baseados em aplicativos ou imagens enviadas por usuários, a proposta se concentra na análise espacial do risco em escala de bacia hidrográfica.

Por fim, Paul, Chauhan e Dutta (2023) desenvolveram uma aplicação móvel para interpretação de imagens georreferenciadas com IA e tecnologias geoespaciais abertas. A solução integra aplicativo móvel, banco de dados espacial e WebGIS. O modelo de IA é usado para identificar objetos de interesse nas imagens capturadas em campo, e os dados georreferenciados são enviados a um servidor para visualização posterior. Apesar de utilizar imagem, geolocalização, IA e mapa, o estudo apresenta uma estrutura mais geral, sem foco específico no registro comunitário de alagamentos urbanos.

A Tabela 14 resume os recursos identificados nos estudos acessados e na proposta deste trabalho. A leitura da tabela deve considerar que um mesmo recurso pode ter finalidades diferentes em cada estudo. Por esse motivo, as diferenças são discutidas após a tabela.

Tabela 14 – Comparação de recursos entre os trabalhos relacionados e a proposta desenvolvida.

Trabalho	Colaboração cidadã	App móvel	Sist. web	Mapa ou geolocalização	Uso de imagens	IA ou visão computacional	Estimativa automática de profundidade/altura
Narayanan et al. (2014)	✓	×	×	✓	✓	✓	✓
Sulistyo et al. (2025)	✓	✓	✓	✓	✓	×	×
Alizadeh e Behzadan (2023)	✓	✓	×	✓	✓	✓	✓
Ajin et al. (2025)	×	×	×	✓	×	×	×
Paul, Chauhan e Dutta (2023)	×	✓	✓	✓	✓	✓	×
Este trabalho	✓	✓	✓	✓	✓	✓	×

Fonte: Elaborado pela autora.

A comparação mostra que a presença de um recurso não significa que ele seja usado com o mesmo objetivo. Em Narayanan et al. (2014) e Alizadeh e Behzadan

(2023), as imagens são utilizadas para estimar automaticamente o nível ou a profundidade da água. Nos dois casos, a análise depende de objetos de referência presentes na cena, como prédios, postes ou placas de trânsito. A proposta deste trabalho segue outro caminho. O aplicativo desenvolvido não busca calcular automaticamente a profundidade do alagamento a partir desses objetos. A imagem é usada como evidência do relato e como entrada para apoio da IA na triagem dos registros antes da publicação.

O estudo de [Sulistyo et al. \(2025\)](#) é o que mais se aproxima da proposta quanto à coleta colaborativa. Os autores utilizam ciência cidadã, aplicativo móvel, sistema *web*, geolocalização e imagens. A diferença principal está no uso dos dados. Em [Sulistyo et al. \(2025\)](#), a coleta organiza informações sobre inundações para visualização em WebGIS e uso posterior em sistemas de informação geográfica. Neste trabalho, a coleta também é colaborativa, mas faz parte de um fluxo voltado ao registro comunitário em tempo real, com envio de imagem, indicação do nível observado, localização no mapa e análise antes da publicação.

Os trabalhos de [Ajin et al. \(2025\)](#) e [Paul, Chauhan e Dutta \(2023\)](#) contribuem para situar a proposta em relação ao uso de tecnologias geoespaciais. [Ajin et al. \(2025\)](#) trabalha com mapeamento de risco em escala de bacia hidrográfica, a partir de fatores de perigo, vulnerabilidade e exposição. Esse objetivo se distancia do aplicativo desenvolvido, pois não envolve registro comunitário de ocorrências em tempo real. [Paul, Chauhan e Dutta \(2023\)](#), por sua vez, integra aplicativo móvel, imagem, geolocalização, IA e WebGIS, mas apresenta uma proposta mais geral de interpretação de imagens georreferenciadas, sem foco específico em alagamentos urbanos.

Com base nos estudos acessados, a revisão permite responder às três questões de pesquisa definidas no planejamento. Em relação à **QP1**, foram identificadas soluções voltadas ao monitoramento, à coleta, ao mapeamento e à análise de eventos de inundação. Os trabalhos incluem abordagens para estimar nível ou profundidade da água por imagens, aplicações móveis para coleta colaborativa, sistemas *web* ou WebGIS e modelos de mapeamento de risco.

Quanto à **QP2**, os recursos mais recorrentes foram aplicativo móvel, sistema *web*, geolocalização, uso de imagens, participação cidadã, IA, visão computacional e tecnologias geoespaciais. Esses recursos aparecem em combinações diferentes. Em [Narayanan et al. \(2014\)](#) e [Alizadeh e Behzadan \(2023\)](#), as imagens e a visão computacional são usadas para estimar o nível ou a profundidade da água. Em [Sulistyo et al. \(2025\)](#), a aplicação móvel e o sistema *web* apoiam a coleta e a organização dos dados. Em [Ajin et al. \(2025\)](#), o foco está na análise espacial do risco. Em [Paul, Chauhan e Dutta \(2023\)](#), a IA é aplicada à interpretação de imagens georreferenciadas.

A **QP3** foi respondida pela comparação entre os trabalhos relacionados e a proposta desta pesquisa. A maior proximidade está nos estudos que combinam participação de usuários, imagens e localização geográfica, especialmente [Narayanan et al. \(2014\)](#), [Sulistyo et al. \(2025\)](#) e [Alizadeh e Behzadan \(2023\)](#). Também há aproximação com [Paul, Chauhan e Dutta \(2023\)](#), pela integração entre aplicativo

móvel, imagem, geolocalização, IA e visualização em mapa. As diferenças aparecem no objetivo de cada solução. Alguns trabalhos usam imagens para estimar a altura ou a profundidade da água, enquanto outros priorizam a organização de dados, o mapeamento de risco ou a interpretação geoespacial de imagens.

A diferença central deste trabalho não está apenas na presença de aplicativo, mapa, imagem ou IA. A contribuição está na combinação desses recursos em um fluxo voltado ao uso comunitário. O usuário registra um ponto de alagamento, informa o nível observado, envia uma imagem e acompanha a ocorrência no mapa. A IA atua como apoio à análise da imagem, não como mecanismo para medir a profundidade da água. Com isso, a proposta prioriza a confiabilidade do registro colaborativo antes da disponibilização das informações para a comunidade.

7 Considerações finais

Este trabalho teve como objetivo desenvolver um aplicativo móvel colaborativo para o monitoramento em tempo real de áreas alagadas, permitindo que a população registre e visualize pontos de alagamento em áreas urbanas. A proposta partiu da necessidade de ampliar o acesso a informações locais durante períodos de chuva intensa, principalmente em situações nas quais os dados oficiais podem não representar, com detalhe suficiente, a condição observada em ruas, bairros e trajetos cotidianos (TUCCI, 2007; IPEA, 2012; HILLEBRAND et al., 2026).

O sistema desenvolvido reuniu os principais recursos definidos nos objetivos do trabalho. Foram implementados o fluxo de registro de ocorrências, a marcação do ponto no mapa, o envio de imagem, a indicação do nível do alagamento, a autenticação por SMS e a visualização dos relatos no painel administrativo. O painel permite que gestores analisem os registros recebidos, consultem as informações da ocorrência e aprovem ou rejeitem os relatos antes de sua disponibilização à comunidade. Esse fluxo reforça a preocupação com a confiabilidade das informações publicadas, sem eliminar a participação dos usuários no processo de monitoramento.

A revisão dos trabalhos relacionados mostrou que há pesquisas voltadas ao uso de imagens, geolocalização, participação cidadã, sensores, plataformas de dados e IA em contextos de alagamentos, enchentes e inundações. Entre os estudos analisados, observou-se maior proximidade com propostas que combinam registros visuais, localização e colaboração dos usuários (NARAYANAN et al., 2014; OJHA et al., 2025; MONDAL et al., 2025). A solução desenvolvida se diferencia por integrar, em um mesmo fluxo, o registro comunitário de pontos de alagamento, a evidência visual, a localização no mapa, a revisão administrativa e o apoio de IA na triagem das imagens.

A experimentação com modelos multimodais abertos indicou que a IA pode apoiar a análise preliminar das imagens enviadas pelos usuários. Os resultados mostraram diferenças entre os modelos avaliados, tanto nas métricas de classificação quanto no tempo de resposta e no consumo de tokens. O modelo `qwen3.5-9b` apresentou o melhor desempenho médio em *F1-score* e acurácia, enquanto o `qwen3-vl-4b`

apresentou uma relação mais favorável entre qualidade da classificação e tempo de execução. Esse resultado indica que a escolha do modelo não deve considerar apenas a maior pontuação final, mas também o custo de execução e a adequação ao fluxo de triagem do aplicativo.

A análise dos erros também reforçou a necessidade de manter a validação humana no processo. Falsos positivos podem comprometer a confiabilidade do mapa ao permitir a aceitação de imagens inadequadas. Falsos negativos podem impedir o aproveitamento de registros reais enviados pela comunidade. Por isso, a IA foi tratada como uma camada de apoio à decisão, e não como substituta da análise feita pelo gestor. Essa escolha é coerente com a proposta do sistema, pois permite usar a IA para organizar e sinalizar os relatos recebidos, mantendo a decisão final no painel administrativo.

Como limitação, destaca-se que a avaliação dos modelos foi realizada com uma base previamente organizada de imagens e com execução local dos modelos. Embora esse procedimento tenha permitido comparar diferentes configurações, ainda é necessário observar o comportamento da solução em cenários reais de uso, com imagens enviadas por usuários em diferentes condições de iluminação, enquadramento, qualidade e contexto. Também é necessário avaliar a experiência dos usuários e dos gestores no uso contínuo do aplicativo.

Como trabalhos futuros, sugere-se ampliar a base de imagens utilizada na experimentação, incluindo novos cenários urbanos e diferentes níveis de alagamento. Também podem ser realizados testes com usuários para avaliar a clareza do fluxo de registro, a facilidade de uso do mapa e a utilidade das informações exibidas. Outra possibilidade é ajustar os critérios de triagem automatizada a partir de dados coletados em uso real, observando em quais situações a análise por IA, os metadados, a localização e as respostas colaborativas contribuem com maior precisão para a validação dos relatos.

De modo geral, os resultados obtidos indicam que a proposta atingiu os objetivos definidos para este trabalho. O aplicativo desenvolvido oferece uma solução inicial para o registro e a visualização colaborativa de áreas alagadas, enquanto a experimentação com IA mostrou caminhos para apoiar a triagem das imagens enviadas. A combinação entre participação comunitária, validação administrativa e análise automatizada pode contribuir para melhorar o fluxo de informações durante eventos de chuva intensa e apoiar decisões mais seguras pela população.

Referências

- AJIN, R. S. et al. Flood risk mapping in an urbanized tropical river basin in India using MCDA-AHP: a post-storm event evaluation. *Smart Construction and Sustainable Cities*, v. 3, n. 10, 2025. Citado 4 vezes nas páginas 7, 42, 43 e 44.
- ALIZADEH, B.; BEHZADAN, A. H. Scalable flood inundation mapping using deep convolutional networks and traffic signage. *Computational Urban Science*, v. 3, n. 17, 2023. Citado 5 vezes nas páginas 11, 12, 42, 43 e 44.
- CARTERETTE, B. Precision and recall. In: *Encyclopedia of Database Systems*. [S.l.]: Springer, 2018. Citado na página 14.
- CASTRO, M. E. V.; FIGUEIREDO, A. M. d. O.; NASCIMENTO, A. C. R. B. d. *Protótipo de Aplicativo para Alerta de Cheias: Enchentes SOS*. [S.l.], 2024. Citado 3 vezes nas páginas 3, 4 e 10.
- FARIAS, A. Riscos socioambientais de inundação urbana sob a perspectiva do Sistema Ambiental Urbano. *Sociedade & Natureza*, 2022. Citado 3 vezes nas páginas 3, 7 e 8.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Citado na página 14.
- HILLEBRAND, F. L. et al. Construção da Bacia Escola do Rio Rolante, Rio Grande do Sul, para a gestão integrada dos desastres e dos recursos hídricos. 2026. Manuscrito. Citado 6 vezes nas páginas 3, 4, 8, 9, 10 e 45.
- HIRATA, E. et al. Mapeamento dinâmico e colaborativo de alagamentos na cidade de São Paulo. *Boletim de Ciências Geodésicas*, 2013. Citado na página 3.
- IPEA. *Atlas da Vulnerabilidade Social nos Municípios Brasileiros*. Brasília: [s.n.], 2012. Relatório técnico. Disponível em: <<https://ivs.ipea.gov.br>>. Acesso em: 20 jun. 2025. Citado 2 vezes nas páginas 3 e 45.
- KITCHENHAM, B. et al. Systematic literature reviews in software engineering – a systematic literature review. *Information and Software Technology*, Elsevier, v. 51, n. 1, p. 7–15, 2009. Citado na página 39.
- KOBIYAMA, M. et al. Bacia escola: modelo para a gestão integrada dos recursos hídricos. *Revista Geonorte*, v. 15, n. 51, p. 1–28, 2024. Citado 2 vezes nas páginas 4 e 9.
- KUHN, M.; JOHNSON, K. *Applied Predictive Modeling*. [S.l.]: Springer, 2016. Citado na página 13.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. Citado na página 43.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, v. 60, n. 2, p. 91–110, 2004. Citado na página 42.

MALCZEWSKI, J. *GIS and Multicriteria Decision Analysis*. New York: Wiley, 1999. Citado na página 43.

MDN Web Docs. *One-time passwords (OTPs)*. 2025. Acesso em: 11 jun. 2026. Disponível em: <<https://developer.mozilla.org/en-US/docs/Web/Security/Authentication/OTP>>. Citado na página 19.

MONDAL, K. P. et al. Engaging youth in flood risk management: A citizen science geospatial initiative in Bangladesh. In: PAL, I. et al. (Ed.). *Proceedings of the 3rd International Symposium on Disaster Resilience and Sustainable Development—Volume 3*. Singapore: Springer, 2025, (Lecture Notes in Civil Engineering, v. 660). p. 153–169. Citado na página 45.

MURPHY, K. P. *Machine Learning: A Probabilistic Perspective*. [S.l.]: MIT Press, 2012. Citado na página 14.

NARAYANAN, R. et al. A novel approach to urban flood monitoring using computer vision. In: *2014 Fifth International Conference on Computing, Communications and Networking Technologies (ICCCNT)*. [S.l.]: IEEE, 2014. p. 1–7. Citado 7 vezes nas páginas 10, 11, 12, 42, 43, 44 e 45.

OJHA, M. et al. Enhancing flood resilience through crowdsourced building porosity mapping: A case study of MIT campus. In: FILHO, W. L. et al. (Ed.). *North American and European Perspectives on Sustainability in Higher Education*. Cham: Springer, 2025, (World Sustainability Series). p. 435–454. Citado na página 45.

Open Geospatial Consortium. *Web Map Service*. 2026. Acesso em: 17 jun. 2026. Disponível em: <<https://www.ogc.org/standards/wms/>>. Citado na página 42.

PAUL, A.; CHAUHAN, S.; DUTTA, D. Mobile-based image interpretation and geotagging using artificial intelligence and open-source geospatial technology. *Applied Geomatics*, v. 15, p. 795–805, 2023. Citado 3 vezes nas páginas 42, 43 e 44.

SAATY, T. L. *The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation*. New York: McGraw-Hill, 1980. Citado na página 43.

SULISTYO, T. et al. Mobile and web-based application as a tool for flood data collection based on citizen science. *Earth Science Informatics*, v. 18, n. 344, 2025. Citado 4 vezes nas páginas 10, 42, 43 e 44.

TAHERNEJAD, A. et al. Application of artificial intelligence in triage in emergencies and disasters: A systematic review. *BMC Public Health*, v. 24, n. 1, p. 3203, 2024. Disponível em: <<https://doi.org/10.1186/s12889-024-20447-3>>. Acesso em: 25 jun. 2025. Citado 5 vezes nas páginas 3, 5, 7, 12 e 13.

TING, K. M. Confusion matrix. In: *Encyclopedia of Machine Learning and Data Mining*. [S.l.]: Springer, 2018. Citado na página 13.

TUCCI, C. E. M. *Inundações urbanas*. Porto Alegre: ABRH, 2007. Citado 4 vezes nas páginas [3](#), [7](#), [8](#) e [45](#).

ZHANG, E.; ZHANG, Y. Precision. In: *Encyclopedia of Database Systems*. [S.l.]: Springer, 2018. Citado na página [14](#).

APÊNDICE A – *Prompts* utilizados na experimentação

1 *Prompt* completo

ID: full_prompt

SYSTEM:

Você é um especialista em análise forense visual e monitoramento de alagamentos urbanos.

USER:

Sua tarefa é analisar imagens enviadas por usuários para verificar autenticidade da imagem, presença de alagamento e possíveis tentativas de fraude ou manipulação.

Para este experimento, interprete `fraud_suspected` como indicador de imagem suspeita, inválida, fraudada ou inadequada para comprovar um alagamento real. Portanto, `fraud_suspected` NÃO significa apenas montagem digital: ele deve ser `true` também quando a imagem não mostrar nenhum tipo de alagamento urbano.

Analise cuidadosamente a imagem considerando as seguintes dimensões:

1. AUTENTICIDADE DA IMAGEM

Verifique se a imagem parece ser uma fotografia real de um ambiente físico.

Sinais de imagem inválida incluem:

- screenshot de aplicativo ou rede social
- foto exibida em tela de celular, computador ou televisão
- foto de outra foto impressa
- imagem claramente gerada por computador, ilustração ou renderização 3D
- presença de interface de aplicativo, barras de status ou menus
- imagem antiga, histórica ou de outra época, especialmente em preto e branco, sépia ou com aparência de arquivo histórico, pois não representa um evento atual válido para comprovação

2. MANIPULAÇÃO DIGITAL OU MONTAGEM

Procure sinais de edição ou manipulação visual, como:

- iluminação inconsistente entre objetos
- sombras incompatíveis com a direção da luz
- brilho diferente em partes da imagem
- bordas recortadas indicando possível colagem
- halos ou contornos artificiais em objetos
- sinais de que um objeto foi retirado de outra foto e inserido na imagem
- distorções no fundo da imagem
- inconsistências de perspectiva

- texturas desalinhadas
- padrões repetidos artificialmente
- áreas pixeladas ou com resolução diferente do restante da imagem
- artefatos de compressão inconsistentes

3. SINAIS DE IMAGEM GERADA POR IA

Observe possíveis artefatos típicos de imagens geradas por IA, como:

- objetos deformados ou incompletos
- padrões repetitivos ou artificiais
- textos ilegíveis em placas ou sinais
- reflexos impossíveis ou inconsistentes
- estruturas urbanas fisicamente impossíveis
- incoerência entre objetos e cenário

4. DETECÇÃO DE ALAGAMENTO

Avalie a presença de água acumulada no ambiente urbano e classifique o nível:

- leve: quando a água cobre apenas a rua e é rasa, com trânsito possível
- moderado: quando invade calçadas, interiores de residências, comércios ou cobre parte das rodas e dificulta o trânsito
- interditado: quando há submersão significativa e impossibilidade de circulação

Importante:

- água no interior de residências, comércios ou outros ambientes construídos também deve ser considerada válida como evidência de inundação/alagamento, e NÃO deve ser tratada como fraude apenas por não ocorrer na via pública
- não considerar como alagamento: poças isoladas, chão molhado, água na sarjeta, praia, lago, rio ou piscina

5. CONSISTÊNCIA FÍSICA DA CENA

Avalie continuidade da água, reflexos naturais, interação com objetos e coerência com inclinação da rua ou do ambiente.

6. REGRA OBRIGATÓRIA PARA `fraud_suspected`

Defina como `true` quando:

- não houver alagamento urbano ou inundação válida visível
- houver apenas água superficial sem caracterização de alagamento
- for screenshot, foto de tela, imagem gerada por IA ou imagem manipulada
- a imagem for antiga, histórica, de outra época ou em preto e branco/sépia, de modo a não representar evidência atual válida

Defina como `false` apenas quando houver foto real com alagamento ou inundação visível e compatível com um evento válido, inclusive em ruas, calçadas, áreas urbanas externas ou interiores de residências/comércios afetados pela água.

7. REGRAS DE CONSISTÊNCIA FINAL

- Se `flood_detected` for `false`, então `flood_level` deve ser `none` e `fraud_suspected` deve ser `true`.
- Baixa qualidade sozinha não caracteriza fraude.
- Se algum campo não puder ser determinado, use `none`.

Analise cuidadosamente a imagem enviada. Avalie autenticidade, presença de alagamento, possíveis manipulações e qualidade da evidência. Lembre-se: se não houver alagamento urbano visível, `fraud_suspected` deve ser `true`. O mesmo vale para screenshots, fotos de telas/dispositivos, fotos de outras fotos, imagens geradas por IA, renderizações e montagens.

2 *Prompt* intermediário

ID: `medium_prompt`

SYSTEM:

Você é um especialista em análise forense visual de imagens de alagamentos urbanos.

USER:

Analise a imagem e determine se há alagamento, o nível estimado e se a imagem é suspeita ou inválida.

Considere:

1. AUTENTICIDADE

A imagem deve ser uma foto real.

É fraude se for:

- screenshot, foto de tela ou de outra imagem
- imagem gerada por IA, ilustração ou renderização
- imagem manipulada
- imagem antiga/histórica, por exemplo preto e branco ou sépia

2. ALAGAMENTO

Considere válido quando houver água acumulada em ambiente urbano, incluindo:

- ruas, calçadas
- interiores de casas ou comércios, o que NÃO é fraude por si só

Classifique:

- leve: água rasa na rua
- moderado: invade calçadas/interiores ou cobre rodas
- interditado: submersão significativa

Não é alagamento:

- poças isoladas, chão molhado
- praia, rio, lago ou piscina

3. CONSISTÊNCIA

A água deve ser contínua, com reflexos e interação física coerente.

4. REGRA DE FRAUDE

`fraud_suspected` deve ser `true` quando:

- não houver alagamento válido
- imagem inválida, como IA, tela, manipulada ou antiga

`fraud_suspected` deve ser `false` apenas quando:

- for foto real com alagamento visível, inclusive em interior

5. CONSISTÊNCIA FINAL

- Se `flood_detected` for `false`, `flood_level` deve ser `none` e `fraud_suspected` deve ser `true`.
- Se incerto, use `none` para o nível.

Observe a imagem e responda de forma direta se ela parece válida, se há alagamento urbano visível e qual o nível estimado.

3 *Prompt* mínimo

ID: `minimal_prompt`

SYSTEM:

Você analisa imagens de alagamentos urbanos.

USER:

Analise a imagem e aplique estas regras:

1. É fraude quando:

- não há alagamento válido
- é screenshot, foto de tela ou imagem de outra imagem
- é gerada por IA, manipulada ou ilustrativa
- é antiga/histórica, por exemplo preto e branco ou sépia

2. É válido quando:

- é foto real
- há água acumulada em ambiente urbano, como rua, calçada ou interior de casas/comércios

3. Níveis:

- leve: água rasa na rua
- moderado: invade calçada/interior ou cobre rodas
- interditado: submersão significativa

4. Não é alagamento:

- poças isoladas, chão molhado
- praia, rio, lago, piscina

5. Regras finais:

- sem alagamento, `flood_detected` deve ser `false`, `flood_level` deve ser `none` e `fraud_suspected` deve ser `true`
- baixa qualidade não é fraude por si só

Agradecimentos

Agradeço ao meu orientador, Frederico Schardong, pelo acompanhamento, pela disponibilidade e pelas contribuições durante o desenvolvimento deste trabalho. Ao meu companheiro, Leonardo Passos, agradeço pelo apoio, pela compreensão e pelo incentivo durante esta trajetória. A todos aqueles que contribuíram, de alguma forma, para a realização deste trabalho, deixo meu sincero agradecimento.

Dedicatória

Dedico este trabalho à memória de minha mãe, que teve um papel essencial em minha formação e sempre reconheceu a importância dos estudos. Embora não esteja presente para acompanhar esta conquista, os ensinamentos, o apoio e as oportunidades que ela me proporcionou foram fundamentais para que eu chegasse até aqui.