

## **COMPARAÇÃO DAS VETORIZAÇÕES DAS FEIÇÕES DE EDIFICAÇÕES ATRAVÉS DE DADOS DO OPEN STREET MAP BUILDINGS, GOOGLE OPEN BUILDINGS V3 E ATRAVÉS DE IMAGENS DE DRONE COM RTK EM ÁREAS INUNDADAS DO VALE DO TAQUARI – RS**

*BUILDING FOOTPRINT VECTORIZATIONS COMPARISON: OPENSTREETMAP BUILDINGS,  
GOOGLE OPEN BUILDINGS V3, AND RTK DRONE IMAGES IN FLOODED AREAS OF THE  
TAQUARI VALLEY – RS*

**Guilherme Gandra Franco, Guilherme Garcia de Oliveira**

Universidade Federal do Rio Grande do Sul. Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia. Avenida Bento Gonçalves, 9500. Câmpus do Vale, Sector 5. Prédio 44202. Porto Alegre – RS – Brasil.  
E-mails: guigandra@yahoo.om.br; g.g.oliveira10@gmail.com

Introdução  
Materiais e métodos  
Discussões e resultados  
Considerações finais  
Agradecimentos  
Disponibilização do código  
Referências

**RESUMO** - O Brasil tem sido afetado por eventos extremos de grandes proporções e a integração de tecnologias avançadas de sensoriamento remoto com inteligência artificial (IA) tem sido fundamental para monitorar e responder rapidamente a estes desastres. Este estudo avaliou a qualidade de dados geoespaciais gratuitos disponibilizados pelos projetos Open Street Maps Buildings (OSM) e Open Buildings V3 da Google, comparando suas informações à restituição aerofotogramétrica gerada a partir de ortomosaicos na região do Vale do Taquari, no Rio Grande do Sul. A escolha da área considerou os eventos hidrológicos extremos de 2023 e 2024, que resultaram em graves danos materiais, incluindo a danificação e destruição de centenas de edificações. A análise desenvolveu um algoritmo para examinar a quantidade de edificações identificadas e suas respectivas similaridades geométricas com base no índice de Jaccard. Os resultados indicaram uma similaridade de 31,9% para o OSM e 34,5% para o Open Buildings V3 em relação às feições de referência. Além disso, foi possível quantificar as unidades e deferir que para algumas aplicações, estas fontes podem comprometer a qualidade de caracterização dos cenários emergenciais.

**Palavras-chave:** Índice de Jaccard. Aeronave Remotamente Pilotada. Desastres hidrológicos. Cadastro Técnico Multifinalitário.

**ABSTRACT** - Brazil has been affected by large-scale extreme events, and the integration of advanced Remote Sensing technologies with Artificial Intelligence (AI) has been crucial for monitoring and rapidly responding to these disasters. This study evaluated the quality of free geospatial data provided by the OpenStreetMap Buildings (OSM) and Google's Open Buildings V3 projects, comparing their information to photogrammetric restitution generated from orthomosaics in the Taquari Valley region, Rio Grande do Sul. The study area was selected based on the extreme hydrological events of 2023 and 2024, which caused severe material damage, including the destruction and damage of hundreds of buildings. The analysis developed an algorithm to examine the number of identified buildings and their geometric similarities using the Jaccard index. The results indicated a similarity of 31.9% for OSM and 34.5% for Open Buildings V3 compared to the reference features. Additionally, it was possible to quantify the building units and determine that, for certain applications, these data sources may compromise the quality of emergency scenario characterization.

**Keywords:** Geographic Object-Based Image Analysis (GEOBIA). Volunteered Geographic Information (VGI). Building Footprint.

### **INTRODUÇÃO**

Desastres estão cada vez mais recorrentes em diversas partes do mundo e por possuir características continentais, o Brasil se estabelece como palco para diversas manifestações da natureza, principalmente no que tange aos eventos extremos geológicos, hidrológicos, meteorológicos e climáticos.

Fenômenos atmosféricos relacionados à Zona de Convergência do Atlântico Sul (ZCAS), ao *El Niño* e à *La Niña* têm um impacto direto no regime de chuvas em todo o país.

O *El Niño*, por exemplo, resulta em períodos prolongados de seca, principalmente nas regiões

Norte e Centro Oeste, ao passo que, no Sul e Sudeste registram-se volumes de chuvas acima do esperado (Oliveira, 2001; Ab'Sáber, 2003; Cunha et al., 2019; CPTEC-INPE, 2023).

Associado aos perigos e ameaças naturais, o Brasil apresenta características socioeconômicas e de configuração da ocupação do território, delineada por aglomerações em centros urbanos, algumas vezes sem planejamento, que levam a uma iminente possibilidade de que uma significativa parcela da população possa ser afetada diretamente ou indiretamente por alguns destes eventos (Saito et al., 2019).

Dada a natureza espacial dos desastres, a integração de dados geográficos provenientes de sensoriamento remoto e levantamentos de campo torna-se fundamental para garantir uma resposta rápida e eficaz.

Sistemas globais, como o *International Charter for Space and Major Disasters* e o UN-SPIDER, juntamente com iniciativas nacionais, como o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) no Brasil, utilizam dados de satélites, radares e redes de estações para monitorar eventos e emitir os mais diversos tipos de alertas contra eventos extremos.

Além disso, a evolução dos sensores remotos, especialmente com o advento dos *drones*, trouxe uma nova escala de trabalho, que permitiu a obtenção de dados de altíssima resolução a baixos custos (Tomaszewski, 2014; Kucharczyk & Hugenholtz, 2021; SEDEC, 2024).

Complementando os métodos avançados de obtenção e tratamento de dados espaciais, a Informação Geográfica Voluntária (*Volunteered Geographic Information - VGI*) também se configura como uma alternativa relevante para obtenção de dados espaciais. Um dos projetos de VGI mais bem sucedidos, o Open Street Map (OSM), atua com milhões de colaboradores ao redor do mundo. Fornece informações vetoriais, como edifícios, vias e infraestrutura urbana, amplamente utilizadas para respostas humanitárias frente a desastres e planejamento urbano a partir de coleções de imagens disponibilizadas pela Microsoft *Bing Maps* e Maxar (Fan et al., 2014; Tian et al., 2019).

Simultaneamente, a Inteligência Artificial (IA), especialmente por meio de técnicas de visão computacional associadas ao aprendizado profundo, tem se destacado como uma ferramenta essencial para a detecção automática de feições geográficas com precisão em ambientes de alta complexidade. A disponibilidade crescente de dados ópticos, que agora alcançam escalas de *zettabytes* ( $10^{21}$  bytes), tornou a análise manual desafiadora, diante das constantes atualizações dos acervos. Nesse cenário, a IA se consolida como uma solução indispensável para processar e interpretar essas informações em tempo hábil (Chuvieco, 2020; Li et al., 2021).

Neste âmbito da automação, a *Google Research* desenvolveu um conjunto de algoritmos de aprendizado de máquina capaz de detectar e mapear automaticamente edifícios a partir de imagens de satélite de alta resolução, denominado Open

Buildings V3 (IA Google).

Segundo Sirkó et al. (2021), o produto consiste em aproximadamente 1,8 bilhões de contornos de edifícios, que cobrem 58 milhões de km<sup>2</sup> na África, América Latina, Caribe, Sul da Ásia e Sudeste Asiático, com inferência realizada em maio de 2023. Modelos baseados nesta tecnologia são denominados *Geographic Object-Based Image Analysis (GEOBIA)*, uma abordagem que segmenta a imagem em objetos ou regiões com características homogêneas (como cor, forma ou textura), ao invés de analisar pixel a pixel.

Essa técnica permite identificar padrões espaciais mais complexos e contextuais, sendo especialmente útil em ambientes urbanos com alta densidade de elementos (Mohammad & Chen, 2019). Este método, segundo Machado et al. (2021), associado a técnicas de aprendizado profundo de máquinas, vem sendo amplamente utilizado em imagens de alta resolução com o intuito de melhorar o tempo de obtenção de feições geográficas, principalmente em ambientes urbanos, com alta complexidade de objetos (Aboud Neta et al., 2018).

Ainda que existam técnicas de detecção automática de objetos, métodos de cadastro urbano que dependem de habilidades humanas de interpretação e desenho são empregados há décadas, com o foco na elevada precisão e acurácia cartográfica dos produtos gerados.

De acordo com Silva (2023), o Cadastro Territorial Multifinalitário (CTM) é uma ferramenta técnica essencial para a administração pública, independentemente do tamanho do município. Consiste na transferência dos dados espaciais georreferenciados, como quadras, logradouros, lotes e edificações para um ambiente digital, baseado em normas de Padrão de Exatidão Cartográfica (PEC) bem como nas da Associação Brasileira de Normas Técnicas (ABNT).

Ele é fundamental para plano diretores, tributos, facilita a gestão territorial, e colabora com a manutenção e criação de políticas urbanas, no entanto, muitos municípios não implementam o CTM devido à falta de recursos financeiros e à complexidade técnica envolvida (Cunha et al., 2019; Teixeira et al., 2020).

Como proposta de solução alternativa para municípios que ainda não possuem um CTM consolidado, de acordo com as normas técnicas vigentes da NBR 14166, este estudo visa verificar a qualidade posicional e quantificar o número de edificações disponíveis no OSM, bem como

as detectadas automaticamente pela IA Google.

Para isso, foram realizados levantamentos cadastrais oriundos de ortofotos georreferenciadas obtidas por *drones*, semelhantes aos utilizados nos CTMs, em recortes territoriais amostrais de quatro municípios afetados pelas inundações de setembro de 2023 e maio de 2024, na região do Vale do Taquari, Rio Grande do Sul (Belletini et al., 2024).

Diante desse cenário, este estudo busca contribuir para o aprimoramento das respostas emergenciais frente a desastres hidrológicos, ao avaliar criticamente a qualidade e a aplicabilidade dessas fontes cartográficas alternativas.

## MATERIAIS E MÉTODOS

Inicialmente, para definição das áreas para análises e testes, foi mapeada a mancha de inundação total do evento na Bacia Hidrográfica do Taquari-Antas, delimitada a partir de uma metodologia integrada envolvendo: i) a amostragem de pontos limites da cheia com uso de imagens obtidas por sensoriamento remoto e trabalhos de campo; ii) a interpolação das cotas de inundação; iii) a integração da superfície de cotas de inundação com o Modelo Digital de Elevação (MDE) para estimativa do alcance da inundação e profundidade das águas. Para tal, foram usadas imagens da constelação de satélites

Em contextos de alta complexidade operacional, onde o tempo é um fator decisivo e a integridade de comunidades e da infraestrutura está em risco, o acesso a informações geográficas ágeis pode ser determinante para salvar vidas. No entanto, os resultados preliminares apontam para discrepâncias significativas quando comparadas aos levantamentos cadastrais obtidos por *drones*, o que evidencia limitações importantes dessas tecnologias. Assim, o objetivo do estudo não é substituir metodologias, mas compreender em que medida essas ferramentas podem servir como suporte provisório à tomada de decisão em situações imediatas.

*Planet*, da missão *Skysat* e o MDE FABDEM (*Forest And Buildings removed Copernicus Digital Elevation Model*). O produto gerado nesta etapa foi disponibilizado no Banco de dados das cheias na Região Hidrográfica do Lago Guaíba em maio de 2024 (Possantti et al., 2025).

Uma vez que a extensão da inundação ultrapassou 47.884 hectares, o que exigiria um substancial número de voos para ser integralmente coberta, foram selecionadas áreas urbanizadas nos municípios Roca Sales, Encantado, Muçum e Santa Tereza, que totalizaram 970 hectares (Figura 1).

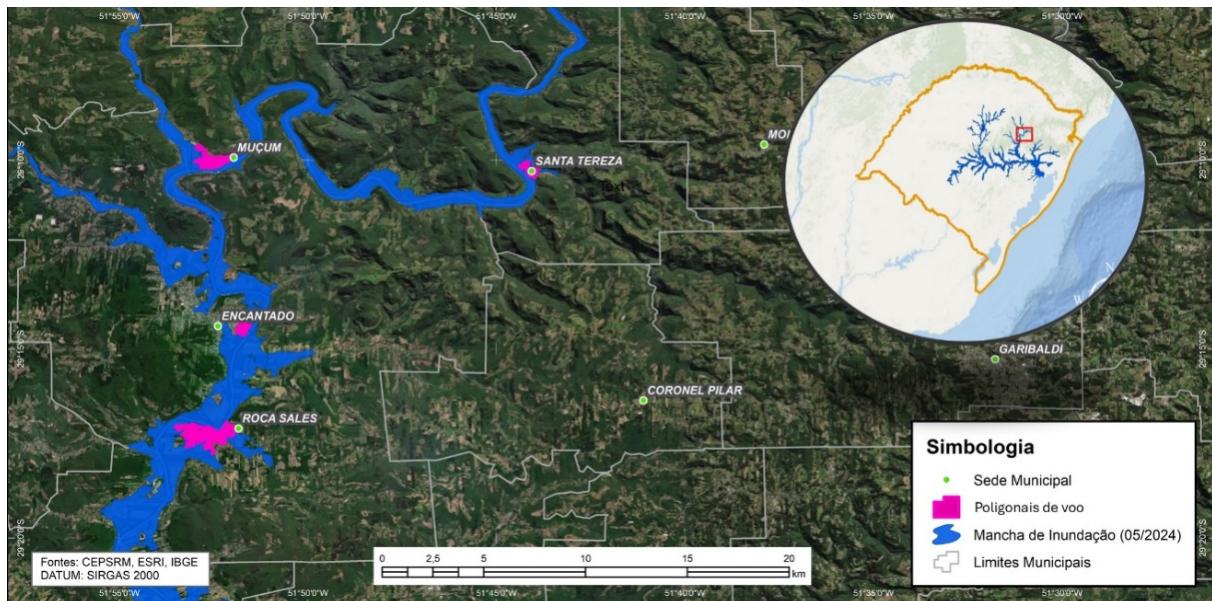


Figura 1 – Mancha de inundação na Bacia do Taquari-Antas e poligonais de voo realizadas por drone.

A escolha da área de estudo foi motivada pelos eventos hidrológicos extremos ocorridos em setembro de 2023 e maio de 2024, que afetaram severamente o estado do Rio Grande do Sul devido à intensidade das chuvas, e as inundações e enxurradas resultantes. Somente o desastre de

maio de 2024 afetou mais de 2,3 milhões de pessoas, com 183 mortes e 27 desaparecidos.

Durante esse período, os acumulados de precipitação atingiram 667 mm em abril e 803 mm em maio, registrados em curtos intervalos de tempo (Reboita et al., 2024).

Já a eleição dos quatro recortes urbanos a serem testadas foi orientada por dois critérios principais: i) representatividade do impacto das inundações, com registros de óbitos e graves danos estruturais; ii) viabilidade técnica e logística de realização dos voos com drones e deslocamento por vias de acesso.

Além disso, esta seleção buscou garantir diversidade espacial dentro da mancha de inundação, priorizando setores urbanos com densidade construtiva significativa para permitir uma avaliação mais robusta da acurácia dos dados alternativos.

Foram geradas quatro poligonais, uma para cada município indicado na figura 1, que contemplasse o tecido urbano e a mancha de inundação. Estas poligonais foram inseridas para a controladora de voo do equipamento utilizado para a missão: DJI Mavic 3E com módulo *Real Time Kinematics* (RTK) instalado. As principais características do modelo escolhido se deram em função da alta qualidade da câmera (20 megapixels), que permitiu um *Ground Sample Distance* (GSD) de 4 cm e pela presença do sistema RTK nativo, que corrige em tempo real as coordenadas do centro da foto, a partir de uma base de referência. Os voos ocorreram no mês de julho de 2024.

O método de correção das fotos capturadas adotado foi o *Networked Transport of RTCM via Internet Protocol* (NTrip). A correção em tempo real utiliza tecnologia móvel 4G para conexão com a base da Rede Brasileira de Monitoramento Contínuo (RBMC) mantida pelo Instituto Brasileiro de Geografia e Estatística (IBGE), localizada no Departamento de Geodésia, no câmpus da

Universidade Federal do Rio Grande do Sul, a aproximadamente 90 km da área mapeada.

Os voos ocorreram com sobreposição lateral e longitudinal de 70%, a uma altura de 120 m em relação ao terreno. Para a montagem do plano e configuração de parâmetros, foi utilizado o aplicativo DJI Pilot 2. A solução permitiu o acompanhamento relativo da superfície terrestre, a partir do carregamento de um MDE de referência, ou seja, a variação do gradiente do terreno balizou a altura do voo para que os 120 m de distância fossem mantidos em grande parte do percurso dos voos realizados.

Foram coletadas 4961 fotos com orientação nadiral, processadas no software Agisoft Metashape versão 2.0 para geração do MDE e ortomosaico.

Após carregamento no software, as imagens foram alinhadas através do reconhecimento de pontos homólogos, gerando uma nuvem de pontos esparsa. Os processos de apontamento de coordenadas não foram realizados, uma vez que a correção em tempo real do posicionamento da câmera ocorreu no modo NTRIP. Na segunda etapa do processamento, iniciou-se a densificação da nuvem para geração do primeiro subproduto da aerofotogrametria, o Modelo Digital de Superfície (MDS).

O Metashape utiliza este modelo para ortorretificar as imagens, com isso, o software corrige as distorções causadas pela paralaxe. Por fim, as imagens retificadas foram mescladas para formar o ortomosaico, no qual foi definido o GSD de 4 cm. As ortofotos foram exportadas para o formato Geotiff, para que pudesse ser manuseada em softwares de geoprocessamento (Figura 2).



**Figura 2** – Ilustração do ortomosaico em um segmento urbano de Roca Sales-RS severamente atingido pela inundaçāo em 2024 e restituição manual das edificações.

A restituição das edificações foi realizada no software ArcGIS Pro 3.0, enquanto o *download* dos dados do OSM Buildings e da IA Google ocorreu na plataforma *Google Earth Engine* (GEE), a partir de códigos disponibilizados nas páginas oficiais dos respectivos projetos. Ambas as coleções foram filtradas para a área de interesse, exportadas no formato GeoJSON e, posteriormente, convertidas para o formato *shapefile*, reprojetadas para o sistema SIRGAS 2000 UTM Zona 22S (EPSG:31982) no ArcGIS Pro.

Dessa forma, foram constituídos três conjuntos de dados: dois gerados manualmente por humanos, por meio da interpretação de imagens e um obtido automaticamente por algoritmos baseados

em IA, conforme a Figura 3. Para cada conjunto, foram calculados os valores de área das projeções das edificações em metros quadrados e as coordenadas dos centróides (X, Y) no sistema UTM selecionado.

Para elaboração e execução do algoritmo comparativo, foi utilizado o ambiente Google Colab, com o carregamento de bibliotecas de código aberto como GeoPanda, para manipulação de dados geoespaciais em Python e Jaccard\_index, projetada para calcular o índice de Jaccard (1) entre dois polígonos, uma métrica amplamente utilizada em visão computacional para quantificar a similaridade entre formas geométricas (Naumann et al., 2024).



**Figura 3 – Sobreposição das três fontes de dados utilizados em algumas quadras do município de Muçum, RS**

O índice é definido como a razão entre a área da interseção dos polígonos e a área da união deles, e resulta numa medida proporcional de

$$J(A, B) = (|A \cap B|) / (|A \cup B|)$$

Em que:

J é a distância de Jaccard;

A é o conjunto de dados restituídos a partir das ortofotos obtidas pelo drone;

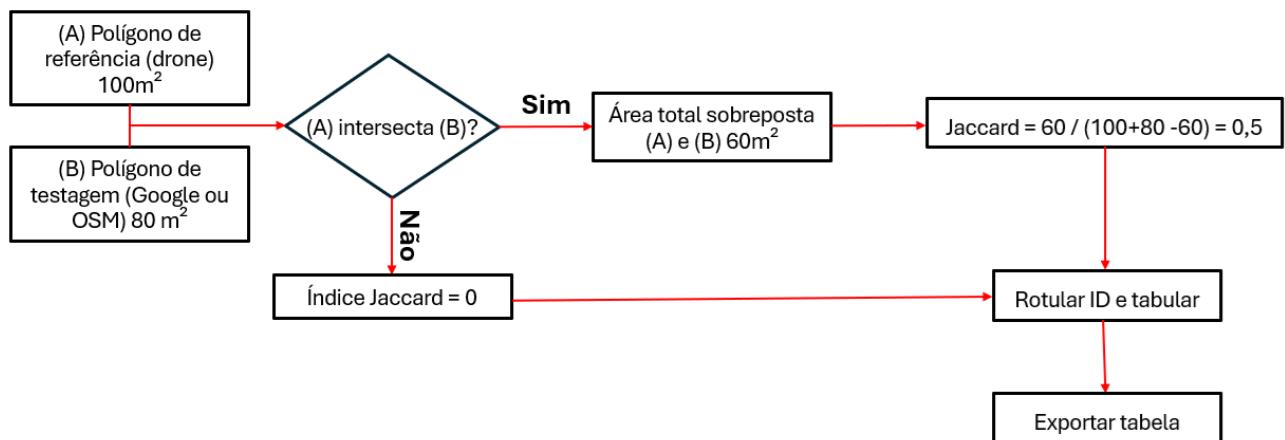
B é o conjunto de dados do OSM e Open Buildings;

sobreposição espacial entre 0 e 1, onde 0 indica que não há similaridade e 1 indica que os conjuntos são idênticos. A equação utilizada foi:

$|A \cap B|$  é o número de elementos que estão presentes em ambos os conjuntos A e B;

$|A \cup B|$  é o número total de elementos que estão presentes em pelo menos um dos conjuntos.

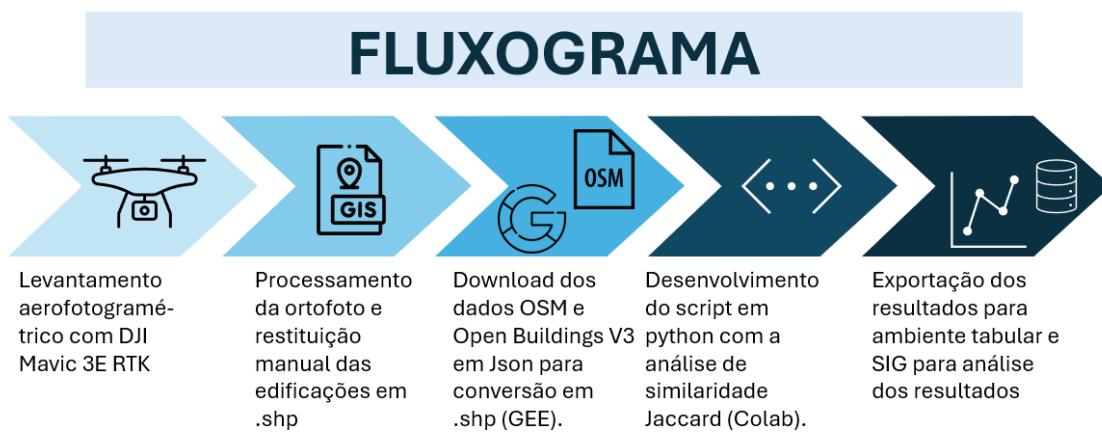
O processo foi representado em fluxograma (Figura 4), para simplificar a compreensão das etapas de preparação, cálculo e exportação dos resultados.



**Figura 4** – Fluxograma que exemplifica uma aplicação hipotética do Índice de Jaccard

Como o algoritmo comparou dois conjuntos de dados com uma base referencial, foi necessário realizar o comparativo em duas etapas. Na primeira, os dados do OSM foram comparados com a restituição manual, e na segunda, os dados da IA Google foram

comparados com a mesma base de referência. O resultado foi um arquivo csv e um *shapefile* contendo feições de polígonos com o grau de similaridade do seu correspondente. A figura 5 sistematiza todo o processo metodológico descrito.



**Figura 5** – Fluxograma dos processos desenvolvidos.

Apesar do rigor metodológico adotado, este estudo apresenta algumas limitações. Primeiramente, a extensão da área analisada representa apenas uma fração do total afetado, o que restringe a generalização dos resultados para toda a Bacia do Taquari-Antas. Em segundo lugar, a ausência de pontos de controle independentes (GCPs) em campo pode impactar a validação posicional dos

produtos gerados, mesmo com o uso de correção RTK em tempo real. Além disso, o processo de restituição manual está sujeito a variações interpretativas, especialmente em áreas onde as edificações foram parcialmente destruídas. Por fim, as bases comparadas (OSM e IA Google) possuem temporalidades distintas, o que pode influenciar os índices de similaridade calculados (Figura 6).

## DISCUSSÕES E RESULTADOS

Foram contabilizadas 4.205 feições de edificações restituídas de forma manual, a partir das ortofotos produzidas pelo levantamento aerofotogramétrico, com projeção de 668.637 m<sup>2</sup> de área edificada dentro da mancha de inundação. O conjunto de dados OSM, restituídos por VGI, totalizou 3.930 feições e área de 647.777 m<sup>2</sup> ao passo que a IA da Google, computou 725.430 m<sup>2</sup> em 6.122 unidades (Tabela 1).

O conjunto gerado por IA apresentou um

aumento significativo no número de feições, com 45,5% a mais em relação à vetorização de referência e 55,8% a mais em comparação ao OSM. Em termos de área total da projeção das edificações, a IA computou valores 8,5% superiores à vetorização manual e 12% acima dos dados do OSM. Por outro lado, a diferença de apenas 3,1% entre a vetorização manual e o OSM destaca uma maior proximidade entre esses dois conjuntos de dados e métodos.



**Figura 6** – Demonstração do algoritmo com o índice de Jaccard nas feições OSM e Open Buildings V3.

**Tabela 1** – Dados quantitativos das três bases avaliadas: número de feições e área edificada.

Base de Dados	Número de Feições	Área Edificada (m <sup>2</sup> )
Vectorização Manual	4.205	668.637
OSM (VGI)	3.930	647.777
IA Google (Open Buildings V3)	6.122	725.430

No que tange a estatística descritiva (Tabela 2), a média da IA Google (0,345) supera a do OSM (0,319), com isso, em termos gerais, os polígonos gerados pela IA apresentam maior alinhamento com o referencial.

**Tabela 2** – Dados quantitativos das três bases avaliadas: número de feições e área edificada.

Métrica	OSM	IA Google
Média	0,319	0,345
Desvio Padrão	0,259	0,273
Valor Mínimo	0,000	0,000
1º Quartil (25%)	0,037	0,046
Mediana (50%)	0,333	0,361
3º Quartil (75%)	0,537	0,597
Valor Máximo	0,914	0,919

O desvio padrão da IA Google é ligeiramente maior (0,273 contra 0,259), que sugere maior variabilidade nos resultados, o que pode indicar tanto um potencial para identificar características distintas quanto uma menor consistência em alguns casos.

Os valores mínimo e máximo mostram que ambos os conjuntos alcançam níveis comparáveis de similaridade máxima, mas o desempenho geral da IA Google se destaca nos quartis: no 1º quartil, a IA apresenta 0,046 contra 0,037 do OSM, sugere-se que mesmo os valores mais baixos de similaridade da IA são superiores; na mediana, a IA alcança 0,361, enquanto o OSM fica em 0,333, reforça que, em mais da metade dos casos, a IA obtém maior similaridade. O 3º quartil também é favorável à IA, com 0,597 contra

0,537, demonstra que os índices mais elevados estão mais concentrados na IA Google.

Esses resultados indicam que a IA não apenas supera o OSM em termos de desempenho geral, mas também apresenta uma maior frequência de índices de similaridade elevados, o que a torna mais confiável na maioria das comparações realizadas.

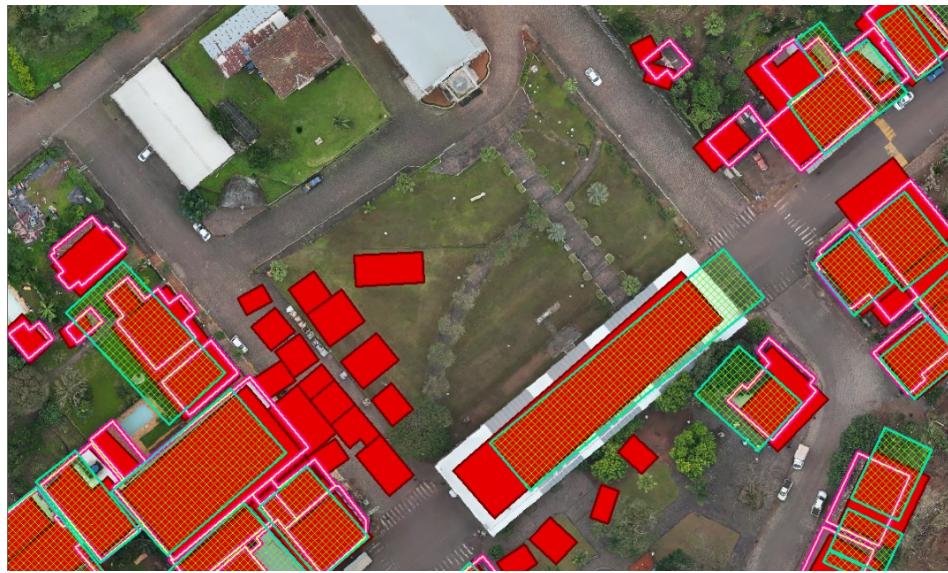
Em suma, o conjunto Google foi o melhor em 58,3% dos casos, enquanto o OSM foi o melhor em 41,7%. Isso indica que, em termos de similaridade com a base referencial, os polígonos gerados pela IA do Google apresentaram um desempenho superior na maioria das comparações, no entanto, não foi considerado o fato da IA possuir maior quantidade de feições.

Os resultados indicam que o algoritmo de visão computacional da Google se mostra um pouco mais eficaz na identificação e delimitação de construções. Contudo, a comparação do número absoluto de feições revela uma diferença significativa dele com os dois grupos de dados, que sugere uma elevada taxa de dados errôneos. Esta incongruência pode levar ao superdimensionamento de eventuais unidades imobiliárias atingidas na área de estudo.

A diferença de 12% na mensuração da área da projeção de edificação frente aos 45,5% do quantitativo pode revelar a fragmentação de edificações ou até na identificação de elementos não caracterizados como imóveis.

A figura 7a exemplifica um trecho da ortofoto do mês de julho de 2024 e a Figura 7b, um registro de satélite do dia 31 de agosto de 2022 na mesma região, obtida pelo software Google Earth, no

qual é possível identificar tendas provisórias na Praça da Matriz de Muçum, que possivelmente subsidiou a restituição da IA da Google, que as classificou como edificações na IA Google.



**Figura 7a** – Demonstração do algoritmo com o índice de Jaccard nas feições OSM e Open Buildings V3.



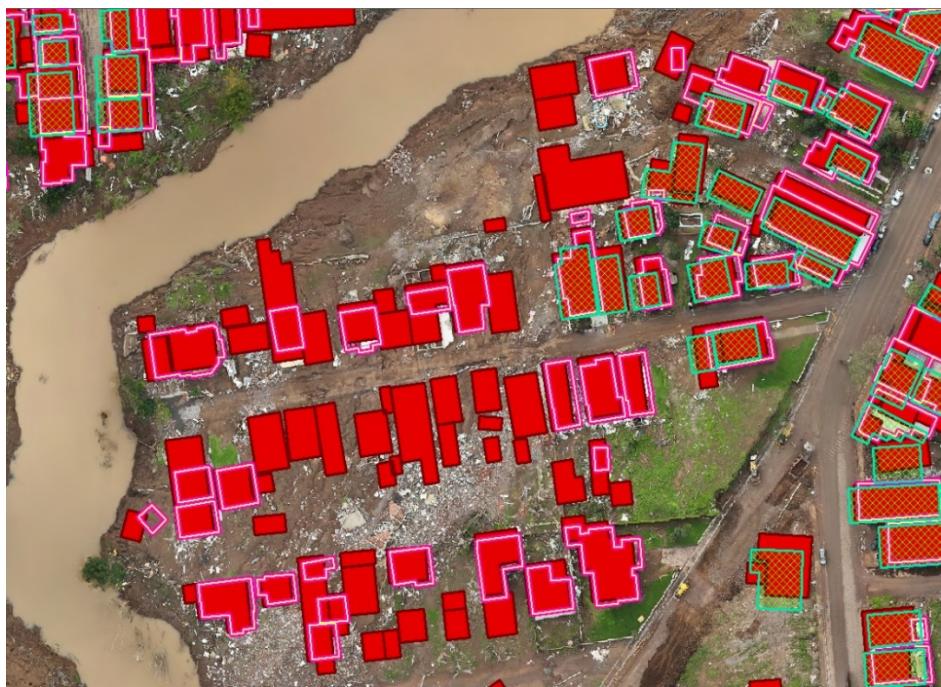
**Figura 7b** – Imagem de satélite da Praça da Matriz de Muçum do dia 31 de agosto de 2022, com a presença de toldos.

Além disso, cidades são muito dinâmicas, especialmente em regiões sujeitas a eventos extremos, como as áreas avaliadas. Nessas circunstâncias, edificações que anteriormente constavam nos mapeamentos podem ter sido destruídas pelos desastres posteriores à restituição. Essa defasagem temporal entre a data do mapeamento do OSM e IA Google e a ocorrência de algum evento, pode levar a inconsistências nos novos dados gerados, como o representado na figura 8, no município de Roca Sales, onde grande parte dos imóveis que margearam um curso d'água foi destruída nos eventos de setembro de 2023 e de

maio de 2024.

Portanto, a atualização frequente dos dados e a consideração de mudanças recentes no território são indispensáveis para reduzir distorções e garantir maior confiabilidade das análises realizadas.

Cabe ainda ressaltar que algumas pesquisas semelhantes foram realizadas, como Chamberlain et al. (2024), que comparou as projeções de edificações africanas no Google Open Buildings, Microsoft Building Footprints, Ecopia Digitize Africa e OpenStreetMap, no entanto, sem uma base cartográfica referencial como a deste estudo.



**Figura 8** – Diferença na resolução temporal dos dados Google e OSM com os restituídos manualmente no ano de 2024.

Ainda assim, foi possível destacar que nenhum dos produtos foi considerado um "dado de verdade terrestre" (*ground truth*), a análise não buscou validar a precisão absoluta das edificações mapeadas, mas sim entender como esses produtos diferem entre si em diferentes contextos espaciais, como áreas urbanas e rurais.

Cabe ainda ressaltar que das discrepâncias observadas entre as bases analisadas podem ter relação à resolução espacial dos dados utilizados. As ortofotos obtidas com *drone*, com GSD de 4 cm, proporcionam um nível de detalhamento significativamente superior em comparação às imagens de satélite utilizadas como base para o OpenStreetMap e o Google Open Buildings V3, cuja resolução varia de 50 cm a 1 metro.

Além disso as imagens de *drones* são ortorretificadas num MDS com melhor resolução espacial, gerado no próprio software, a partir da estereoscopia digital subsidiada pelo algoritmo *Structure From Motion* (SfM). Portanto, a resolução espacial deve ser considerada um fator determinante na análise da qualidade das restituições.

Os resultados obtidos reforçam a importância

de avaliações críticas e localizadas do uso de tecnologias emergentes em contextos de desastres. Embora a IA da Google tenha apresentado melhor desempenho em termos de similaridade espacial, a elevada quantidade de feições identificadas erroneamente levanta preocupações sobre o uso indiscriminado desses dados em ações emergenciais, como estimativas de danos e alocação de recursos.

Nesse sentido, torna-se essencial que gestores públicos e profissionais de planejamento urbano considerem não apenas a disponibilidade dessas bases, mas também suas limitações técnicas e temporais. A ausência de atualização contínua e o uso de imagens antigas podem comprometer decisões em contextos de alta urgência. Assim, este estudo contribui para o debate sobre o papel dessas tecnologias no suporte à gestão de risco e destaca a necessidade de protocolos que combinem agilidade, acurácia e validação local, especialmente em municípios que não dispõem de infraestrutura cartográfica consolidada. A incorporação dessas reflexões no desenvolvimento de políticas públicas pode ampliar a resiliência territorial frente a eventos extremos.

## CONSIDERAÇÕES FINAIS

Os resultados apresentados evidenciam o potencial das ferramentas de Inteligência Artificial e da cartografia colaborativa para mapeamento e análises territoriais, mas também destacam suas limitações significativas em cenários complexos como o estudo de áreas afetadas por desastres.

A IA do Open Buildings V3 demonstrou maior capacidade de identificar feições e alcançar índices médios de similaridade mais elevados, superando o OSM em diversas métricas.

Contudo, a elevada quantidade de feições detectadas pela IA, 45,5% superior à vetorização manual,

sugere problemas de segmentação, que podem resultar em superdimensionamento e comprometer análises críticas em situações de emergências.

A fragmentação de edificações, a identificação de estruturas temporárias e a inclusão de elementos não caracterizados como imóveis pela IA evidenciam a necessidade de validações rigorosas para evitar distorções significativas nas estimativas de impacto.

A discrepância entre o aumento de 12% na área edificada e os 45,5% no número de feições aponta para um tratamento inadequado das características urbanas, como mostrado nos exemplos analisados em Muçum e Roca Sales. Além disso, a defasagem temporal nos dados do OSM e Open Buildings V3 frente aos eventos extremos compromete ainda mais a confiabilidade dos resultados, uma vez que edificações destruídas continuam sendo contabilizadas. Portanto, enquanto as tecnologias automáticas e colaborativas representam avanços relevantes para a rapidez no acesso a informações, o uso exclusivo dessas ferramentas deve ser abordado com cautela em estudos que demandem alta precisão e atualidade.

A integração com métodos tradicionais, como a vetorização manual baseada em imagens recentes, permanece indispensável para garantir maior acurácia, especialmente em cenários de rápida transformação territorial, como os afetados

por desastres extremos.

Essa abordagem híbrida é fundamental para fortalecer respostas humanitárias e subsidiar decisões estratégicas de forma confiável e eficiente.

Este fenômeno reforça a necessidade de uma filtragem prévia rigorosa antes da utilização das informações em testes quantitativos, para evitar a inclusão de edificações irrelevantes ou errôneas. Além disso, as projeções de edificações não consideram a quantidade de pavimentos, resultando em uma estimativa de área edificada afetada que é superior ao constatado nas projeções.

Como direções futuras, recomenda-se expandir a análise em diferentes contextos geográficos, como áreas rurais e regiões metropolitanas com maior densidade de edificações.

Pode-se ainda classificar o uso da edificação (Residencial, Comercial, Industrial) para verificar em quais classes há maior aderência.

Ademais, há potencial para o desenvolvimento análises com diferentes métodos de similaridade, bem como de protocolos operacionais que orientem o uso combinado de ferramentas automatizadas e manuais, para gestão de risco e planejamento territorial. Ao ampliar o escopo de avaliação e consolidar boas práticas, espera-se contribuir para a criação de soluções mais resilientes, escaláveis e eficientes no enfrentamento de desastres em diferentes escalas.

## AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Chamada CNPq/MCTI/FNDCT Nº 18/2021 – Faixa A – Grupos Emergentes, Processo 408489/2021-9 e 311009/2022-0.

## DISPONIBILIZAÇÃO DO CÓDIGO

[https://github.com/guilhermegandra/segmentador\\_PhD/blob/master/COMPARATIVO\\_EDIFICA%C3%87%C3%95ES\\_VALE\\_DO\\_TAQUARI.ipynb](https://github.com/guilhermegandra/segmentador_PhD/blob/master/COMPARATIVO_EDIFICA%C3%87%C3%95ES_VALE_DO_TAQUARI.ipynb)

## REFERÊNCIAS

- AB'SÁBER, A. N. **Os Domínios de Natureza no Brasil: Potencialidades Paisagísticas**. Ateliê Editorial, 2003.
- ABOUD NETA, S.R.; BIAS, E.S.; SANTOS, C.A.M. “Classificação Baseada em Objetos e Mineração de Dados: Aplicação de Ferramentas Open Source no Mapeamento de Área Urbana”. **Revista Brasileira de Cartografia**, v. 70, n. 3, p. 932-966, 2018.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 14166**. Rede de Referência Cadastral Municipal. Rio de Janeiro, 1998.
- BELLETINI, A.; HOEZEL, M.; PERSCH, C.; JOHNER, M. **Mapeamentos Geológico-Geotécnicos Voltados para a Prevenção de Desastres: Avaliação Técnica Pós-Desastre Cruzeiro Do Sul, RS**. Serviço Geológico do Brasil – CPRM, 2024.
- CHAMBERLAIN, H. R.; DARIN, E.; ADEWOLE, W. A.; JOCHEM, W. C.; LAZAR, A. N.; TATEM, A. J. “Building Footprint Data for Countries in Africa: To What Extent are Existing Data Products Comparable”. **Computers, Environment and Urban Systems**, v. 110, 2024.
- CHUVIECO, E. **Fundamentals of Satellite Remote Sensing**. CRC Press, 2020.
- CPTEC INPE. Condições Atuais do ENOS: Caracterização do El Niño. Disp.: <http://enos.cptec.inpe.br/>. Acessado em: 22 jan. 2025.
- CUNHA, E.; OLIVEIRA, F.; JULIÃO, R.; CARNEIRO, A. O Cadastro Urbano no Brasil: Histórico e Evolução. **Revista de Geografia e Ordenamento do Território**, v. 17, p. 55-74, 2019.
- CUNHA, A.P.; ZERI, M.; LEAL, K.R.D.; COSTA, L.C.; CUARTAS, L.A.; MARENKO, J.A.; TOMASELLA, J.; DA SILVA PINTO VIEIRA, R.M.; BARBOSA, A.; CUNNINGHAM, C.; GARCIA, J.V.C.; BROEDEL, E.; ALVALÁ, R.C.D.S.; NETO, G.R. Extreme Drought Events Over Brazil from 2011 to 2019. **Atmosphere**, n. 11, 2019.
- CUNHA, A.P.; ZERI, M.; LEAL, K.R.D.; COSTA, L.C.;

- CUARTAS, L.A.; MARENKO, J.A.; TOMASELLA, J.; DA SILVA PINTO VIEIRA, R.M.; BARBOSA, A.; CUNNINGHAM, C.; GARCIA, J.V.C.; BROEDEL, E.; ALVALÁ, R.C.D.S. & NETO, G.R. A Multi-Scale Analysis of the Extreme Precipitation in Southern Brazil in April/May 2024. *Atmosphere*, v. 15, n. 9, p. 1123, 2024.
- FAN, H.; ZIPF, A.; FU, Q.; NEIS, P. Quality assessment for building footprints data on OpenStreetMap. *International Journal of Geographical Information Science*, v. 28, n.4, p. 700-719. 2014.
- KUCHARCZYK, M. & HUGENHOLTZ, C.H. Remote Sensing of Natural Hazard-Related Disasters with Small Drones: Global Trends, Biases, and Research Opportunities. *Remote Sensing of Environment*, v. 264, p. 112577, 2021.
- LI, Y.; MA, J.; ZHANG, Y. Image Retrieval from Remote Sensing Big Data: A Survey. *Information Fusion*, v. 67, p. 94-115, 2021.
- MACHADO, G.; FERREIRA, E.; NOGUEIRA, K.; OLIVEIRA, H.; BRITO, M.; GAMA, P.; SANTOS, J. AiRound and CV-BrCT: Novel Multiview Datasets for Scene Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 14, p. 488-503, 2021.
- MOHAMMAD, D.H. & CHEN, D. Segmentation for Object-Based Image Analysis (OBIA): a review of algorithms and challenges from remote sensing perspective. *ISPRS. Journal of Photogrammetry and Remote Sensing*. v. 150. P. 115-134. 2019.
- NAUMANN, A.; BONERATH, A.; HAUNERT, J-H. Many-to-many polygon matching a la Jaccard. In: 32 Annual European Symposium on Algorithms (ASA 2024) Schloss Dagstuhl – Leibniz-Zentrum für Informatik, v.308, p. 90: 1-90:15. 2024.
- OLIVEIRA, G. S. *O El Niño e Você – O Fenômeno Climático*. Editora Transtec, 2001.
- POSSANTTI, I.; AGUIRRE, A.; ALBERTI, C.; AZEREDO, L.; BARCELOS, M.; BECKER, F.; CAMANA, M.; CANTOR, G.; CARDozo, T.; CARRARD, G.; CAZANOVA, R.; CAMARGO, P.; CASTILHOS, M.; COLLISCHONN, W.; CORNELY, A.; COSTA, S.; DORNELLES, F.; ECKHARDT, R.; FAN, F.; BERRUTI, R. *Banco de Dados das Cheias na Região Hidrográfica do Lago Guaíba em Maio de 2024* (v. 1.4). Zenodo, 2025.
- REBOITA, M.M; MATTOS, E.V.; CAPUCIN, B.C.; SOUZA, D.O.; FERREIRA, G.W. A multi-scale analysis of the extreme precipitation in southern Brazil in April/May 2024. *Atmosphere*, v. 15, n. 9: 1123, 2024.
- SAITO, S.M.; ASSIS DIAS, M.C.; ALVALÁ, R.C.D.S.; STENNER, C.; FRANCO, C.; RIBEIRO, J.V.M.; DE SOUZA, P.A.; DE MORAES SANTANA, R.A.S. População Urbana Exposta aos Riscos de Deslizamentos, Inundações e Enxurradas no Brasil. *Sociedade & Natureza*, v. 15, n. 9, p. 1123, 2019.
- SILVA, E. *Cadastro Territorial Multifinalitário Aplicado à Gestão Municipal*. UFSC, 2023.
- SIRKO, W.; KASHUBIN, S.; RITTER, M.; ANNKAH, A.; BOUCHAREB, Y.; DAUPHIN, Y.; KEYSERS, D.; NEUMANN, M.; CISSE, M.; QUINN, J. “Continental-Scale Building Detection from High-Resolution Satellite Imagery”. *arXiv*. 2107. 12283, 2021.
- TEIXEIRA, K.; SILVA, E.; SILVA, L.R. Contribuições para Reformulação do Sistema Cadastral Municipal: do Modelo Tradicional ao Multifinalitário. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO E GESTÃO TERRITORIAL, 14. 2020. *Anais...* Florianopolis, 2020.
- TIAN, Y.; ZHOU, Q.; FU, X. Analysis of the evolution, completeness and spatial patterns of OpenStreetMap building data in China. *ISPRS International Journal of Geo-Information*. V.8, 2019.
- TOMASZEWSKI, B. *Geographic Information Systems (GIS) for Disaster Management*. CRC Press, 2014.

*Submetido em 22 de fevereiro de 2025  
Aceito para publicação em 17 de julho de 2025*