



ISSN: 2447-3359

## REVISTA DE GEOCIÊNCIAS DO NORDESTE

### *Northeast Geosciences Journal*

v. 11, nº 2 (2025)

<https://doi.org/10.21680/2447-3359.2025v11n2ID40616>



# Aplicação do Método Ransac na Estabilização do Referencial da Câmera em Inspeções de Alta Precisão Utilizando o Método Correlação de Imagens Digitais

## *Application of The Ransac Method to Stabilize the Camera Referential In High-Precision Inspection Using the Digital Image Correlation Method*

Marcio Augusto Reolon Schmidt<sup>1</sup>; Antônio Carlos dos Santos<sup>2</sup>; Jefferson Rodrigo de Souza<sup>3</sup>; Leandro Nogueira Couto<sup>4</sup>; Luciano Oliveira<sup>5</sup>; Dionatan Fabres Carreço<sup>6</sup>

<sup>1</sup> Universidade Federal de Uberlândia. Faculdade de Engenharia Civil. Uberlândia/MG. Brasil. Email: marcio.schmidt@ufu.br  
ORCID: <https://orcid.org/0000-0003-2716-2360>

<sup>2</sup> Universidade Federal de Uberlândia. Faculdade de Engenharia Civil. Uberlândia/MG. Brasil. Email: acds@ufu.br  
ORCID: <https://orcid.org/0000-0001-9019-4571>

<sup>3</sup> Universidade Federal de Uberlândia. Faculdade de Computação Civil. Uberlândia/MG. Brasil. Email: jrsouza@ufu.br  
ORCID: <https://orcid.org/0000-0001-6422-4722>

<sup>4</sup> Universidade Federal de Uberlândia. Faculdade de Computação Civil. Uberlândia/MG. Brasil. Email: leandronc@ufu.br  
ORCID: <https://orcid.org/0000-0003-2094-1150>

<sup>5</sup> Vale S.A. Engenharia de Ferrovias; Vitória/ES. Brasil. Email: oliveira.luciano@vale.com  
ORCID: <https://orcid.org/0000-0003-0283-4407>

<sup>6</sup> Vale S.A. Engenharia de Ferrovias; Vitória/ES. Brasil. Email: dionatan.carreco@vale.com  
ORCID: <https://orcid.org/0009-0002-5442-8320>

**Resumo:** A inspeção visual é uma atividade importante para garantir a segurança e a eficiência de estruturas ferroviárias, rodoviárias, estruturas geodésicas e geotécnicas. Elementos muito pequenos como as fissuras podem reduzir a resistência e durabilidade das estruturas de concreto, pavimentos asfálticos e sinalização horizontal, taludes entre outros. Os métodos de avaliação convencionais têm limitações de precisão e quantificação da extensão dos danos, pois exigem equipes de inspeção treinadas, carecem de regularidade no monitoramento e estão sujeitos à subjetividade humana. Neste contexto, o método de Correlação de Imagens Digitais (DIC) permite monitorar fissuras em diferentes tipos de estruturas, com imparcialidade e repetibilidade, comparando uma imagem de referência obtida no início do monitoramento em relação a outras imagens obtidas periodicamente. Entretanto, existem desafios operacionais como a manutenção da qualidade geométrica e posicional da referência adotada e seu impacto na posição e atitude do sensor ao longo do tempo. Este artigo avalia a precisão das imagens de inspeção usando drones e injunções de posição com o algoritmo Ransac modificado para fissuras no asfalto e sinalização horizontal. Os resultados apontam a melhora das medidas por meio do tratamento das imagens e consequente comparação dos elementos presentes na cena.

**Palavras-chave:** Inspeção com drones; Estimador Ransac; Correlação de Imagens Digitais.

**Abstract:** Visual inspection is an important activity for ensuring the safety and efficiency of railway, road, geodetic and geotechnical structures. Very small elements such as cracks can reduce the strength and durability of concrete structures, asphalt sidewalks and horizontal signage, slopes and more. Conventional assessment methods have limitations in terms of accuracy and quantifying the extent of damage, as they require trained inspection teams, lack regularity in monitoring and are subject to human subjectivity. In this context, the Digital Image Correlation (DIC) method makes it possible to monitor cracks in different types of structures, with impartiality and repeatability, by comparing a reference image taken at the start of monitoring with other images taken periodically. However, there are operational challenges such as maintaining the geometric and positional quality of the reference adopted and its impact on the position and attitude of the sensor over time. This article evaluates the accuracy of inspection images using drones and position injections with the modified Ransac algorithm for cracks in asphalt and horizontal signs. The results show that the measurements were improved by processing the images and comparing the elements present in the scene.

**Keywords:** Drone inspection; Ransac estimator; Digital image correlation.

Recebido: 25/06/2025; Aceito: 22/01/2025; Publicado: 30/10/2025.

## 1. Introdução

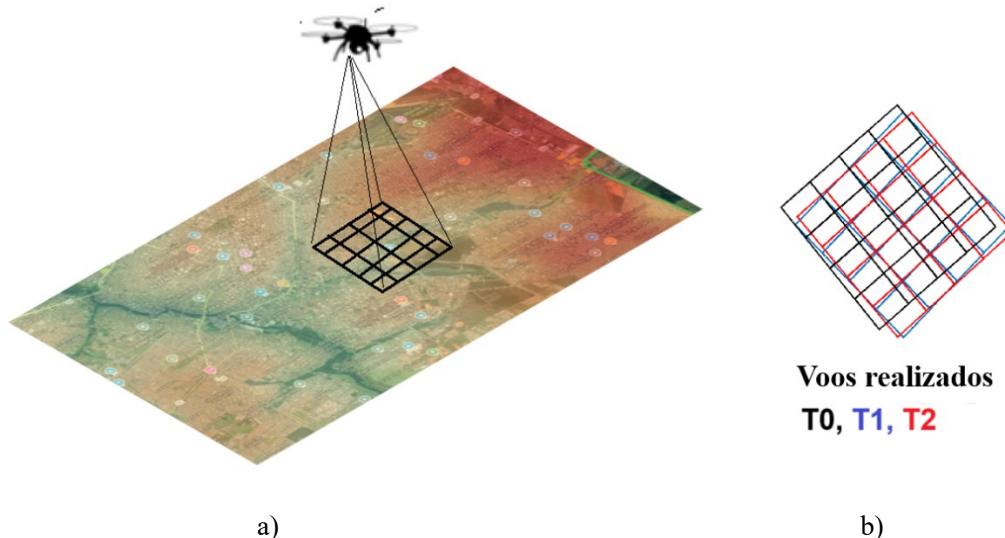
Atividades de monitoramento em diversas aplicações como de uso do solo, rodovias e ferrovias, além de estruturas isoladamente, tem ganhado destaque nos últimos anos (GROSSO ET AL., 2020; LIANG ET AL., 2023; LAVEZZI ET AL., 2024; LIU ET AL., 2024). Nessas o uso de técnicas de imageamento tem ganhado destaque ao permitir o acompanhamento em diferentes escalas de aquisição e processamento com uso de diferentes plataformas. Estas atividades vão desde escalas médias como as mudanças na paisagem e uso do solo por meio do crescimento de áreas antropizadas (ASLAM et al. 2024; WORACHAIRUNGREUNG et al. 2024), passam por escalas grandes como no acompanhamento de fissurações e falhas em pavimentos asfálticos e sinalização horizontal (AL-DOSARI; HUNAITI; BALACHANDRAN. 2023), até a escala de detalhes como na fissuração em concreto que tendem a reduzir a carga efetiva (QIAO et al., 2021; ZHANG et al., 2024) e a durabilidade do material. Portanto, um programa de monitoramento adequado e periódico é necessário para compreender as alterações na resposta estrutural dos elementos (LI; YOU; KAEWUNRUEN. 2022; GHERI et al., 2022) e acompanhamento de expansão e movimentação de estruturas geodésicas e geotécnicas.

Essas aplicações tem em comum a abordagem convencional de inspeção visual para a detecção (LAI. 2024; MOHAMMED et al., 2020). No entanto, essas avaliações têm limitações em termos de precisão e capacidade de quantificar a extensão e o progresso da deterioração de forma sistemática, pois exigem tempo para treinar a equipe de inspeção e carecem de regularidade no monitoramento de manchas e fissuras, além de estarem sujeitas à subjetividade humana na identificação e serem suscetíveis à fadiga, distrações e interrupções do operador.

Neste contexto, a Correlação de Imagens Digitais (DIC) é uma técnica alternativa que permite a mensuração de deformações, deslocamentos e alterações de forma usando instrumentos óticos. De acordo com McCormick e Lord (2010), a técnica DIC é mais precisa e menos subjetiva do que os métodos de mensuração manual e permite uma série de aplicações como movimentações, deflexões e deformações de diferentes tipos de estruturas naturais ou construídas pelo homem. As imagens podem ser obtidas a partir de uma ampla variedade de sensores, incluindo câmeras digitais, vídeo de alta velocidade, *laserscanning* (LAI. 2024), microscópios, incluindo microscópios eletrônicos de varredura (MCCORMIK; LORD, 2010) e imagens sintéticas, como interferômetros de radar e imagens de rugosidade da superfície (ZHOU et al., 2021), e as medições feitas nas imagens podem ser correlacionadas com variações na durabilidade e resistência dos elementos monitorados. Para realizar o DIC uma imagem inicial, correspondente a um estado não deformado, é selecionada como imagem de referência com a qual as imagens subsequentes serão comparadas (MOBASHER. 2016). Uma grade (grid) virtual, com espaçamento uniforme, é usada para dividir a imagem em partes menores (patches) e, após a deformação, os deslocamentos são calculados em relação a cada célula da grade original com a situação deformada para estimar o campo total de deformação.

Um dos desafios considerados mais relevantes para a aplicação da técnica DIC é a falta de consistência na posição das câmeras em relação ao objeto quando o método é aplicado ao ar livre (*in situ*). Nestes casos, ou seja, fora do laboratório, os dispositivos sensores são normalmente incorporados em dispositivos aéreos pilotados remotamente (*Remote Piloted Aircraft - RPA*, normalmente drones ou *Unmanned Aerial Vehicle - UAV*), instalados temporariamente em tripés ou suportes, em veículos robóticos de inspeção remota (*robotic inspection vehicles - RIV*) ou veículos subaquáticos operados remotamente (*Remote Operated Vehicles - ROVs*) (Shah et al., 2024). Então, a cada novo levantamento, a posição do sensor da câmera e a atitude (rotações e translações do sensor) da plataforma podem mudar em relação aos levantamentos anteriores. Mesmo em sistemas RPA que utilizam tecnologia de correção em tempo real (GNSS RTK), esta posição pode ser alterada devido às limitações do sistema de localização em termos de geometria de satélite, propagação de sinal e efeitos ambientais, além de fatores aleatórios como iluminação natural, nuvens, ventos e obstruções temporárias, como pássaros e faixas.

No entanto, os voos de inspeção, em particular, sofrem com a propagação de variações nas diferentes posições do RPA devido a condições ambientais, mas principalmente devido às limitações do próprio sistema GNSS, mesmo com correções em tempo real (RTK). Como resultado, o monitoramento por comparação direta de imagens pode se tornar tendencioso e impreciso devido ao desalinhamento das imagens e à propagação de variações associadas às coordenadas em cada imagem. A figura 1a mostra um esquema de imagens obtidas durante a inspeção periódica e a figura 1b apresenta o efeito das translações e rotações da plataforma quando as imagens são sobrepostas para fins de comparação. Ressalta-se que para escalas de mapeamento, a precisão com uso de sistemas GNSS pode ser suficiente, porém para inspeções de estabilidade e durabilidade estrutural, essas não coincidências das imagens pode levar a avaliações tendenciosas ou mesmo inviabilizar o acompanhamento de movimentações e fissurações nas feições monitoradas.



*Figura 1 - Esquema das alterações a) quando as imagens foram captadas e b) os efeitos na área coberta e nas imagens captadas*  
Fonte: Autores

Uma técnica amplamente utilizada para parametrizar resíduos e deslocamentos é o Método dos Mínimos Quadrados (MMQ). Este método é aplicado para resolver problemas com um sistema redundante de equações geradas a partir do número de incógnitas no modelo. Essa redundância é causada pela determinação das coordenadas do mesmo ponto registrado em diferentes imagens com sobreposição parcial. A partir do modelo matemático, as equações geradas com as observações obtidas das imagens são escritas na sua forma matricial como uma função dos parâmetros através do modelo de ajuste (DALMOLIN, 2017). Considerando o caso mais geral em que a função é não linear, a aplicação dos mínimos quadrados requer a linearização do sistema de equações (Equação 3) na forma (DALMOLIN, 2017):

$$\mathbf{X} = -(\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \quad (1)$$

O vetor de resíduos a ser minimizado depende da matriz  $\mathbf{A}$ , que é a matriz dos coeficientes das variáveis definidas no ponto; os vetores de observações  $\mathbf{L}$  e  $\mathbf{X}$  são os vetores dos parâmetros corrigidos. No entanto, quando o dado não é definido no ajuste convencional, o levantamento pode sofrer translação, rotação e mudança de escala, resultando na singularidade da matriz normal  $\mathbf{A}$  e, consequentemente, tornando impossível a inversão (MAROTTA et al., 2007). Nesse caso, são utilizadas injunções para definir pontos que servirão como pontos de controle, que são pixels de controle no caso do DIC. Em geral, as injunções envolvem pelo menos uma das coordenadas, direção e distância. Dessa forma, a matriz de injunções ficaria assim (Equação 2):

$$\mathbf{R} = \begin{bmatrix} 1 & 0 & 1 & 0 & \dots & 1 & 0 \\ 0 & 1 & 0 & 1 & \dots & 0 & 1 \\ N_1 & -E_1 & N_2 & -E_2 & \dots & N_n & -E_n \\ E_1 & N_1 & E_2 & N_2 & \dots & E_n & N_n \end{bmatrix} \quad (2)$$

Na equação 2,  $N$  e  $E$  são as coordenadas no sistema de projeção cartográfica UTM e podem ser expressas em outra referência coletada. A linearização do modelo com injunções seria (Equação 3) (MAROTTA et al. 2007):

$$x = (A^T PA)^+ APL \quad (3)$$

Onde:

$A^T$  - é a matriz transposta de A

$(A^T PA)^+$  - é a matriz resultante injuncionada.

Aplicar injunções a pixels específicos é complicado e sensível a erros, especialmente em levantamentos com nuvens de pontos geograficamente extensas e muitas coordenadas registradas. Além disso, o ajuste apresenta o desafio de estimar simultaneamente variáveis correlacionadas, o que é realizado num espaço de pesquisa de alta dimensão. Isso torna a otimização dispendiosa e propensa a mínimos locais (GUO; GALLEGO, 2024), tornando o método suscetível a outliers e menos robusto. Para resolver o problema dos outliers, o algoritmo Ransac estima os parâmetros de um determinado modelo a partir de um conjunto de dados contaminado por dados espúrios (outliers), garantindo o número mínimo de observações que se encaixam no modelo (inliers) e eliminando aqueles que diferem dos valores (outliers) de acordo com distribuições não lineares (JANICKA; RAPINSKI, 2014; PÉREZ-SINTICALA et al., 2018). De acordo com Ling et al. (2020), os pixels com inliers são geralmente detectados selecionando aleatoriamente pontos homólogos para determinar os parâmetros de orientação e contando o número de inliers cujos erros de reprojeção estão no nível subpixel. O processo é iterado até que o número máximo de inliers seja encontrado. Além da correspondência geométrica entre as correspondências e os parâmetros de orientação, uma forma alternativa de prever a precisão da correspondência é a confiança da correspondência, que geralmente reflete a significância das correspondências quando comparadas com os resultados de correspondência dos seus pixels circundantes (LING et al., 2020). Este artigo, portanto, propõe que a injunção de posição pode ser aplicada para correção geométrica das imagens entre inspeções, tomando um determinado padrão como referência.

Portanto, o monitoramento de alta precisão ao longo do tempo requer a correção da posição da imagem para determinar adequadamente o progresso do processo de fissuração, movimentação ou outro parâmetro sensível. Este artigo avalia as injunções de posição no método paramétrico de ajuste de observações por estimadores de mínimos quadrados, realizado pela aplicação do algoritmo Ransac, considerando uma imagem padrão obtida na primeira inspeção e avaliando os resíduos das variações posicionais e de escala identificadas nas imagens. Por fim, o estimador é usado para realinear as outras imagens em relação à imagem padrão, como ocorre no processo de inspeção realizado com drones.

## 2. Metodologia

Foram realizados voos de inspeção de sinalização horizontal nas vias públicas do campus Santa Mônica da Universidade Federal de Uberlândia (figura 2), localizado em Uberlândia/MG. O campus ocupa uma área de 280.119 m<sup>2</sup> e atende a um público de 26.270 alunos e funcionários docentes e administrativos (UFU, 2024). Ressalta-se que os voos seguiram as recomendações da regulação nacional para RPAs (RBAC-E 94, ANAC, 2017), e que não houve sobrevoos sobre pessoas de modo a garantir a segurança operacional e aspectos éticos da pesquisa.

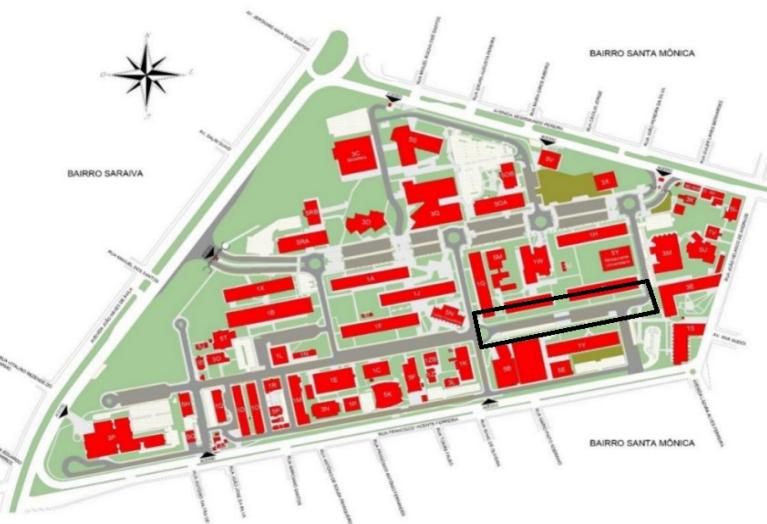


Figura 2 - Identificação da área de teste no campus Santa Mônica da UFU

Fonte: UFU (2024)

Um drone Phantom 4 RTK foi utilizado para realizar os levantamentos. Este equipamento possui um sensor CMOS de 1" capaz de gravar vídeos 4K a 60 fps e fotos com resolução de 20 Mp. Este modelo possui um sistema de posicionamento GPS/GLONASS com um módulo RTK integrado para correções em tempo real dos dados de posicionamento, garantindo precisão centimétrica para levantamentos em tempo real. Grava dados de observação por satélite para aplicações com precisão subcentimétrica utilizando *Post-Processed Kinetics* (PPK) (DJI, 2024). A tabela 1 apresenta as especificações do modelo.

Tabela 1 - Especificações da aeronave remotamente pilotada utilizada

Parâmetros do ARP	
Atributos	Especificações
Marca	DJI
Modelo	Phantom 4 RTK
Peso de decolagem	1391g
Tempo máx. de voo	30 min
Distância máx. de voo	Até 5 km (padrão CE de transmissão)
Velocidade máx. De voo	50 kph (P-mode) ou 58 kph (A-mode)
Temperatura de funcionamento	0° to 40°C
Frequências de funcionamento	2.400 GHz to 2.483 GHz
GNSS	GPS+GLONASS+GALILEO
Hover accuracy Range	0.1m (H e V) com RTK e 0.1m (V) e 0.5m(H) somente GNSS
Sensor	CMOS de 1"
Resolução efetiva	20 Mp
Abertura	f 2.8 a f 11
Tamanho da imagem	4864 x 3648 (4:3)
Estabilização	Triaxial (inclinação, rotação e giro)

Fonte: DJI (URL 1)

Foram realizados oito testes de voo com variações de altura de voo de 20 m e 30 m, configurados com cobertura lateral de 40%, cobertura longitudinal de 70% e velocidades de voo de acordo com o planejamento do software mobile Drone Harmony. Esses voos foram realizados em dias diferentes entre 20 e 26 de fevereiro de 2025, para garantir a variabilidade dos sinais GNSS e das condições do vento, iluminação ambiente e outras interferências para se aproximar das condições reais do levantamento. O software utilizado para o processamento foi o Pixel4Dmapper, da empresa Pix4D. O plano de coleta considerou o uso de dois pontos de controle obtidos com um receptor monofrequência AshTec (portadora L1) com um intervalo de gravação de 5 segundos e uma linha de base para a estação de referência inferior a 100 m da estação RBMC MGUB. O uso de pontos de controle ajuda a minimizar o efeito domo (curvatura das linhas de voo que gera um efeito curvatura convexa em relação ao plano de referência). Como objetos de identificação foram utilizadas fissuras no asfalto, sinalização horizontal e outros elementos presentes em frente ao edifício 1Y no campus da UFU em Santa Mônica.

Neste estudo, a técnica DIC foi aplicada considerando a grade de referência o próprio pixel das imagens, visto que não há uma significativa deformação por efeitos de perspectiva, mas apenas deslocamentos e rotações do referencial do conjunto sensor. Entendendo as imagens do primeiro levantamento de cada área, como instante inicial ( $t_0$ ), como imagens fixas e as demais imagens, comparadas a esta referência, entendidas como imagens a serem ajustadas, procedeu-se a avaliação dos deslocamentos pelo rastreamento do centroíde dos pixels na imagem de referência e seus homólogos nas imagens subsequentes. Ainda que, esta abordagem apresente prejuízo nas áreas de bordas das imagens ajustadas, a área de avaliação é preservada e é possível a correlação dos pontos identificados.

Para a correlação e análise de imagens foi utilizado um script desenvolvido no ambiente Matlab. As etapas do processo compreendem uso dos parâmetros de calibração da câmera como tamanho efetivo da imagem, coordenadas do pixel central e distância focal calibrada, obtidas no processamento no Pix4D; a conversão das imagens para monocromáticas com correção de contraste por threshold automático; aplicação da detecção SURF (*Speed up Robust Feature*); e a identificação de pares de pontos homólogos a partir da limiarização. O detector SURF é superior ao filtro de Harris (HARRIS; STEPHENS. 1988) em termos de número de pontos reconhecíveis (KUCAK et al., 2020), pois enquanto Harris utiliza

limiares e histerese de bordas. calculadas a partir da conversão das imagens para binárias. o Surf identifica *blobs*, ou seja, áreas de intensidade nas imagens processadas como forma de selecionar vértices homólogos e indexar os pixels em pares. Comparados a outros métodos como SIFT e ORB, o estimador SURF se destaca pela eficiência no processamento dos pontos o que o torna eficiente em imagens em diferentes escalas. Este detetor utiliza box-filters sobre a imagem completa e descritores baseados em *wavelet*. o que acelera o processamento e o torna eficiente com imagens em diferentes escalas e garante invariância à rotação e ao contraste (KARAMI; PRASADA; SHEHATA, 2015; BENEVIDES et al., 2022). O método SIFT é um detetor eficaz e eficiente para aspectos geométricos das imagens. mas esbarra no alto custo computacional enquanto que o método ORB utiliza o detector FAST associado ao descritor BRIEF. que incorre em menos robustez no processamento (KARAMI; PRASADA; SHEHATA; 2015).

Uma vez os pixels identificados e indexados. a matriz de pares validados assume o formato Mx3. considerando as suas coordenadas e intensidades associadas. Neste estudo, a matriz fundamental foi construída a partir dos pares de pontos homólogos validados nas etapas anteriores. Esta matriz foi escolhida devido às imagens terem sido coletadas pelo mesmo conjunto sensor em diferentes datas. O uso da matriz essencial não foi possível pois não foi realizada a calibração absoluta da câmera e. devido a questões da posição do drone. assumiu-se a não coplanaridade dos pontos da cena na área de teste. o que inviabiliza a homografia.

A estimativa dos parâmetros da matriz fundamental foi realizada utilizando o método MSAC (YANG et al., 2014; AKDIM et al., 2025). O estimador MSAC (*Modified Ransac*) geralmente converge mais rápido que o Ransac e tem como característica evitar mínimos locais (ZHANG; SHI; XU. 2019) atualizando o índice a cada interação. sendo considerada a distância de Sampson. Essa convergência pode sofrer influência das características das imagens. como o número de detalhes e, por isso, pode ser necessário variar o número de iterações necessárias para definição da matriz.

O número de iterações foi determinado em 2000. após avaliação dos resultados considerando uma variação iniciada em 500. 1000. 2000 e 3000. Finalmente, a transformação geométrica entre as imagens foi calculada utilizando um modelo projetivo, aplicado aos pontos inliers selecionados pelo MSAC sob um limiar na razão de 0.95 e sementes (seed) aleatória a cada teste. Esta transformação permite compensar os deslocamentos relativos entre as posições de tomadas das imagens e as distorções perspectivas causadas pela atitude da plataforma em datas diferentes.

Para avaliação posicional, além da sobreposição e da medida linear entre os pontos foi utilizado o cálculo dos erros quadráticos médios (RMSE) em relação a levantamentos GNSS RTK (*ground control point* – GCP), como em Jiménez-Jiménez et al. (2021) e Guimarães et al. (2025), apresentadas nas equações 6. 7 e 8. e a qualidade verificada com intervalo de confiança a 95% e bootstrap com 1000 amostras.

$$RMSE_x = \sqrt{\frac{\sum_{i=1}^n (x_i - x_r)^2}{n-1}} \quad (6)$$

$$RMSE_y = \sqrt{\frac{\sum_{i=1}^n (y_i - y_r)^2}{n-1}} \quad (7)$$

$$RMSE_r = \sqrt{RMSE_x^2 + RMSE_y^2} \quad (8)$$

### 3. Resultados e discussões

Os resultados da calibração estão apresentados na tabela 2, abaixo. Foi identificada uma distância focal de 8.776mm no sistema sensor do drone Phantom 4.

*Tabela 2 – Parâmetros de calibração obtidos*

---

#### Parâmetros de calibração

---

Parâmetros	Distância Focal (f) (mm)	Centro X (mm)	Centro Y (mm)	R1	R2	R3	T1	T2
Valores Iniciais	8.600	5.676	4.306	-0.270	0.112	-0.032	0.000	-0.001
Valores calibrados	8.776	5.686	4.261	-0.012	-0.005	0.013	-0.001	-0.000
Incertezas (Sigma)	0.013	0.000	0.001	0.000	0.001	0.001	0.000	0.000

Fonte: Autores

Foi selecionado um conjunto de imagens extraídas de duas áreas do campus a partir dos voos realizados e classificados de acordo com a altura do voo. As imagens do primeiro voo em cada altura, 20 m e 30 m, respectivamente, foram utilizadas como dados padrão e denominadas como fixas, pois foram consideradas o primeiro voo de inspeção em cada situação. As imagens dos voos subsequentes foram nomeadas como mov. seguidas do número do voo (mov 01, mov 02 e mov 03). O script desenvolvido realizou uma pesquisa automatizada de pares homólogos do filtro surf que considera a posição e a resposta espectral dos pixels para realizar a correlação em uma lista de pares indexados. O número médio de pixels correlacionados foi de 137 para cada conjunto de imagens (fixo, mov). Como etapa de verificação, os pontos homólogos foram identificados e correlacionados usando linhas para comparação visual (figura 3) com a identificação de pontos internos e a eliminação de pares considerados pontos externos.

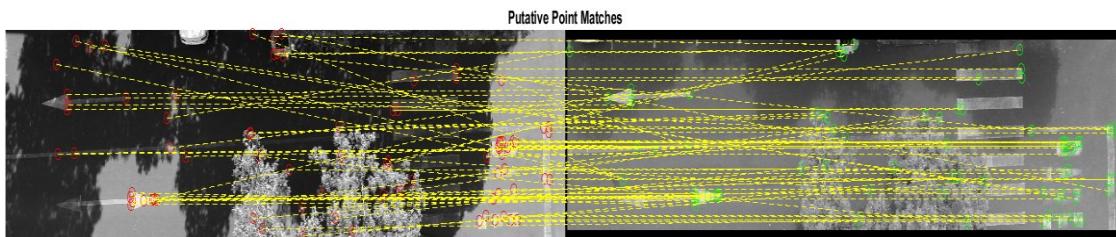
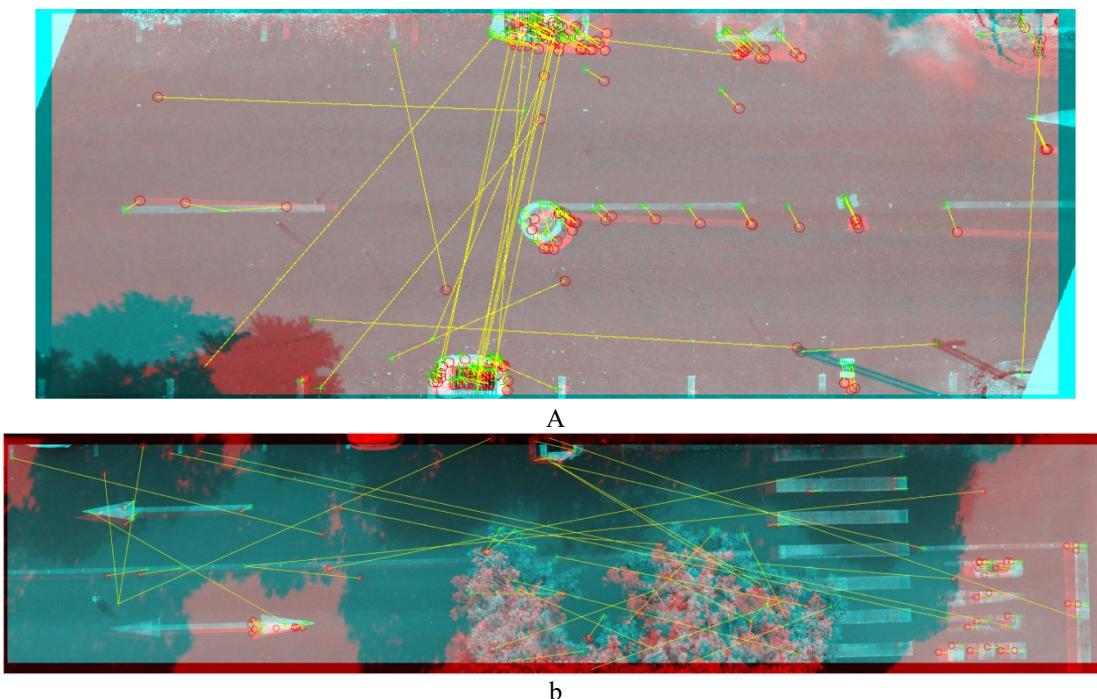


Figura 3 – Indicação dos pontos homólogos identificados  
Fonte: Autores

O método Ransac também foi comparado ao MMQ paramétrico, e o número de interações foi variado para 500, 1000, 2000 e 3000. Essas interações variam de acordo com o esforço computacional necessário para avaliar e resolver as matrizes, eliminando os outliers. Um número menor de interações, da ordem de 500 e 1000, apresentou problemas de não convergência do sistema de equações ou problemas de inversão da matriz característica. Ainda que nenhum dos testes tenha atingido o limiar de 0,95, os valores mais altos de inliers foram atingidos, em sua maioria, com 2000 interações. Os valores dos inliers variaram de 0,471 para o voo de 20m com 500 interações até 0,825 para o mesmo voo com 2000 interações. As demais imagens variaram acima de 0,584 até próximo o valor máximo identificado. Comparativamente, o MMQ apresentou resultados sistematicamente inferiores ao Ransac, mesmo com variações no número de interações.

No entanto, o termo mais relevante para estimar as matrizes foi o número de pares homólogos detectados. Nas diferentes verificações realizadas o número de 60 pares de pixels homólogos sugere ser o limiar para os resultados mais eficazes. Embora a média fosse de 137 pares, três imagens com deslocamentos relativos mais significativos em relação as imagens de controle atingiram apenas 27, 29 e 53 pares homólogos, e os resultados foram imagens com menor aderência à imagem de controle, o que tornaria impossível utilizá-las para monitoramento. Isso também implica que uma área de cobertura de imagem pequena ou imagens com poucos detalhes podem sofrer com o dimensionamento inadequado da matriz de coeficientes ( $A$ ), e a sua inversão pode ser prejudicada, exigindo o uso da matriz pseudo-inversa. A Figura 4a mostra, por exemplo, a combinação da imagem mov 3 sobre o primeiro voo a uma altura de 20 m, e a Figura 4b mostra a imagem mov 2 sobre o voo de 30 m. Nesta figura, alguns dos pares homólogos identificados são mostrados nas imagens sobrepostas. As imagens fixas (imagens padrão) estão destacadas em ciano e as imagens em movimento estão em magenta (Figura 4).



*Figura 4 - Identificação de pares homólogos nas imagens móveis e de referência a) mov3 a 20m de altura. e b) mov2 a 30m de altura.*

*Fonte: Autores*

A matriz fundamental de translação e rotação de cada imagem em movimento em relação à imagem padrão (fixa) foi estimada a partir dos pontos validados. A Tabela 3 mostra os resultados de translação e rotação de cada imagem em movimento em relação às suas imagens fixas, em pixels, utilizando o método Ransac.

*Tabela 3 - Resultados do ajuste da imagem Ransac*

Resultados da matriz pelo método MSAC						
Translação (em pixels)				Rotação (adimensional)		
Altura de voo de 20m						
AREA 1	MOV01	X	Y	Z	0,9480	0,2794
		0,9887	0,1495	0,0068	0,1995	-0,1496
					-0,2478	0,9484
AREA 1	MOV 02	Altura de voo de 30m			-0,9363	0,3495
		-0,9989	-0,0465	-0,0016	0,1012	0,3656
					-0,3364	-0,8627
AREA 1	MOV 03	Altura de voo de 30m			-0,9825	0,1822
		-0,9994	-0,0357	0,0034	-0,0503	-0,0619
					-0,1792	-0,9813
AREA 2	MOV01	Altura de voo de 30m			0,8447	-0,5283
		0,9959	0,0906	-0,0047	0,0801	-0,0327
					0,5292	0,8484
						0,0147

				0,8901	-0,3137	-0,3305	
				-0,3484	-0,0009	-0,9373	
				0,2937	0,9495	-0,1101	
				0,92321	0,2220	0,3137	
				-0,3065	-0,0669	0,9495	
				0,2318	-0,9728	0,0063	
				Altura de voo de 30m			
		X	Y	Z			
					0,5414	0,3594	
					0,7645	-0,5867	
					0,3500	0,7257	
					0,9590	-0,1705	
					-0,2236	0,0355	
					-0,1742	-0,9847	
					0,9904	0,1059	
					0,0808	0,0828	
					-0,1126	0,9909	
					-0,9004	0,1320	
					0,4108	-0,0559	
					-0,1433	-0,9897	
					0,8808	-0,3428	
					-0,3700	-0,0682	
					0,2953	0,9369	
					0,8306	-0,4428	
					-0,3604	0,0352	
					-0,4246	-0,8959	
						-0,1304	

Fonte: Autores

Em relação à precisão geométrica, esses valores podem ser multiplicados pelo GSD (dados de amostragem do solo) de cada voo obtido através do processamento completo dos blocos de levantamento. Para os voos de 20 m, o valor médio do GSD foi de  $0,537 \pm 0,013$  cm/pixel. e os voos de 30 m tiveram um valor médio de GSD de  $0,7983 \pm 0,026$  cm/pixel.

A Tabela 4 mostra a média absoluta dos deslocamentos e a média dos valores absolutos. que é uma medida que calcula a dispersão dos dados e ajuda a identificar valores atípicos. Os valores médios de deslocamento foram calculados usando a distância euclidiana plana de 5,36 mm e 7,94 mm para os voos de 20m e 30m.

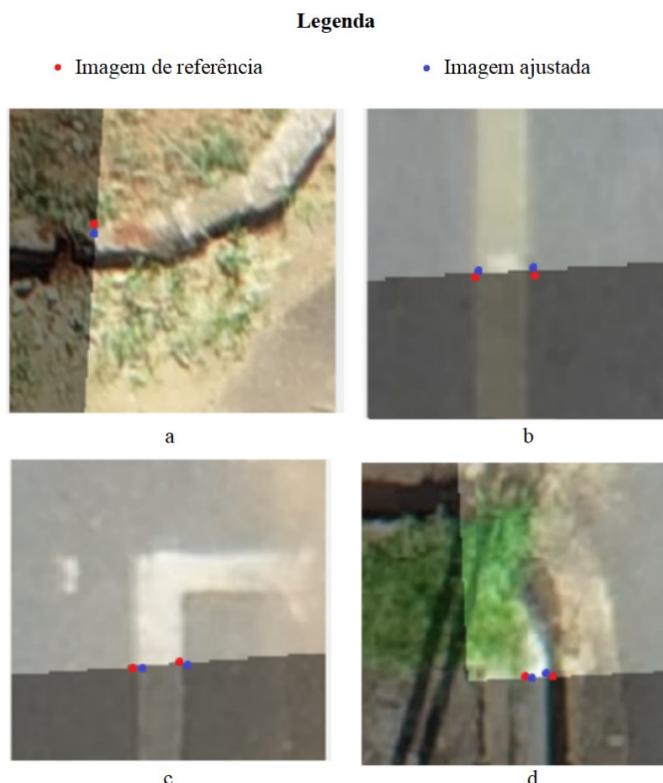
Tabela 4 - Desvios médios entre imagens de referência e móveis após o processamento

		Metros		
		X	Y	Z
20m	Média	0,0053	0,0009	0,0000
	Desvios	0,0001	0,0007	0,0000
30m	Média	0,0076	0,0023	0,0000
	Desvios	0,0002	0,0009	0,0000

Fonte: Autores

Os resultados do ajuste e registro após a aplicação do método MSAC podem ser vistos em detalhes na Figura 5. Na Figura 5a e 5b, voo de 20 m, e na Figura 5c e 5d, o voo de 30 m, os detalhes mostram recortes feitos nas áreas onde as

imagens se sobrepõem, ou seja, as áreas próximas à borda onde as imagens se complementam no mosaico de imagens empilhadas. É possível ver a continuidade das características, de modo que a medição pode ser realizada com o mesmo conjunto de referência para as imagens dos primeiros voos. Os desvios como mostra na tabela 3 ficam abaixo de 7 pixels entre imagens. Foi calculado o RMSE para a componente Leste e para a componente Norte separadamente e depois o RMSE geral pelas fórmulas 6, 7 e 8, chegando a valores de RMSE<sub>x</sub> de 0,979 pixel e 0,949, respectivamente para os voos de 20m e 30m, valores de RMSE<sub>y</sub> de 0,202 pixel e 0,313 pixel para 20m e 30m e o RMSE total de 0,999 pixel para ambos os casos. Esses valores apontam que a componente x teve maiores desvios nos levantamentos realizados e pode significar tendência do sistema para a região.



*Figura 5: Detalhes das imagens corrigidas e sobrepostas após o método Ransac: a) e b) mov03 a 20 m de altura. c) e d) mov03 a de altura 30 m.*

*Fonte: Autores*

Por fim, foi gerada uma análise de significância dos erros de reprojeção para cada um dos conjuntos de imagens analisadas. Foram analisados os critérios de erro médio de reprojeção, desvio padrão do erro, erro máximo de reprojeção e RMSE da reprojeção baseados nos valores de inliers. Os voos realizados com altura de 30m apresentaram os menores valores na análise de erros, sendo que o último dia (4º voo) apresentou erro médio de reprojeção: 0,8804 pixels, desvio padrão do erro: 0,9119 pixel, erro máximo de reprojeção: 4,2944 pixels e RMSE de reprojeção: 1,2593 pixels. A mesma análise para os voos de 20m de altura obtiveram valores mais altos, chegando à análise do mesmo dia (4º voo) apresentar erro médio de reprojeção: 108,3382 pixels, desvio padrão do erro: 418,6456 pixels, erro máximo de reprojeção: 1839,9949 pixels, e RMSE de reprojeção: 425,8492 pixels. Considerando os valores encontrados, esses resultados podem indicar que a altura de voo pode ser um fator de maior relevância na qualidade da reprojeção.

#### 4. Considerações finais

Os fatores ambientais e as características do sistema GNSS podem influenciar a extração de informações geométricas das imagens obtidas em diferentes períodos de monitoramento e degradar a obtenção de medições precisas nas imagens ao

longo do tempo. Neste caso, a precisão das medições é um parâmetro essencial para a correlação com aspectos de durabilidade e resistência dos elementos analisados. Estas diferenças, mesmo que sejam utilizados os mesmos planos de voo e cuidados na configuração da plataforma, podem impossibilitar a comparação direta das imagens num processo de inspeção automatizado.

Neste contexto, a aplicação da abordagem do estimador MSAC para filtrar e registar as imagens revelou-se um método fundamental de controle de qualidade para reduzir as distorções na posição do sensor ao tirar fotografias em momentos diferentes. O processamento e a correção de imagens revelaram-se uma ferramenta importante para corrigir imagens e monitorar fissuras, sinalização horizontal e outras características da área de estudo. Os voos de levantamento realizados alcançaram uma precisão compatível com as atividades de mapeamento topográfico. No entanto, a aplicação do método DIC como ferramenta de inspeção em grande escala requer a correção do centro de perspectiva das imagens obtidas em diferentes campanhas de campo, a fim de medi-las e monitorá-las antes de correlacioná-las com as propriedades físicas e de durabilidade dos elementos inspecionados.

Alternativamente, os resultados indicam que a posição do sensor deve ser fixada sempre que possível, ou que o sistema ótico dos dispositivos sensores deve estar suficientemente próximo do alvo para que os deslocamentos se tornem insignificantes na escala do levantamento. Isto mostra que a escala de monitoramento é influenciada pela plataforma utilizada e que, para uma maior precisão, é necessário reduzir os graus de liberdade dos dispositivos sensores em termos de deslocamento e altitude. Trabalhos futuros poderiam incluir a determinação da altura mínima de voo para aumentar a precisão dos drones e a distância para sensores suportados em tripés ou outros tipos de suporte. a repetição em outras áreas com características distintas como ambientes mais urbanizados.

## Agradecimentos

Os autores gostariam de agradecer à Universidade Federal de Uberlândia e a Vale S.A. pelo apoio e financiamento desta pesquisa, que está associada ao pedido de patente número BR-1020250026880, datado de 11/02/2025.

## Referências

- Akdim. K.; Roukhe. H.; Roukhe. A. Image Registration using Median Absolute Deviation –based Adaptive RANSAC. *Engineering, Technology & Applied Science Research.* n.15. v. 3. 22378–22387. 2025. <https://doi.org/10.48084/etasr.10121>.
- AL-Dosari K.; Hunaiti Z.; Balachandran W. Systematic Review on Civilian Drones in Safety and Security Applications. *Drones.* v.3. n.7. 2023. <https://doi.org/10.3390/drones7030210>
- Aslam. R.W.; Shu.H.; Tariq.A.; Naz.I.; Ahmad. M. N.; Quddoos. A. Javid. K.; Mustafa. F.; Aeman. H. Monitoring landuse change in Uchhali and Khabeki wetland lakes, Pakistan using remote sensing data. *Gondwana Research.* n. 129. 2024. <https://doi.org/10.1016/j.gr.2023.12.015g>
- Benevides. R. A.L.; Pitombeira. K.; Centeno. J.; Simões. P. R. Automatic, accurate and robust image registration with adapted RANSAC (Random Sample Consensus) for SIFT (Scale Invariant Feature Transform) descriptor. (2022). *Research, Society and Development.* 11(14). e383111436631. <https://doi.org/10.33448/rsd-v11i14.36631>
- Dalmolin. Q. Algumas Considerações Sobre a Avaliação Do Resultado De Um Ajustamento De Observações. *Revista Brasileira de Cartografia.* n. 69. v.3. 533-539. 2017. Sociedade Brasileira de Cartografia. Geodésia. Fotogrametria e Sensoriamento Remoto. ISSN: 1808-0936
- DJI. Phantom 4 RTK - Especificações. Disponível em: <https://www.dji.com/br/phantom-4-rtk/info>. Acesso em: 03/04/2025.
- Gehri. N.; Mata-Falcon. J.; Kaufmann. W. Refined extraction of crack characteristics in large-scale concrete experiments based on digital image correlation. *Engineering Structures.* n 251. 2022.h <https://doi.org/10.1016/j.engstruct.2021.113486>
- Grosso. R.; Mecca. U.; Moglia. G.; Prizzon. F.; Rebaudengo. M. Collecting Built Environment Information Using UAVs: Time and Applicability in Building Inspection Activities. *Sustainability.* 12(11). 2020. <https://doi.org/10.3390/su12114731>
- Guimarães. M.J.M; Santos. A. C. da S.; da Silva. A.S. Ribeiro. R.P.; Barros. J.R.A.; Lopes. I. Mapeamento topográfico

- com aeronave remotamente pilotada para fins de georreferenciamento de propriedades rurais. *Revista de Geociências do Nordeste*. v. 11. nº 1. 2025. <https://doi.org/10.21680/2447-3359.2025v11n1ID34481>
- Guo. S.; Gallego. G. Event-based Photometric Bundle Adjustment. *Computer Vision and Pattern Recognition*. 2024. <https://doi.org/10.48550/arXiv.2412.14111>
- Harris. C.; M. Stephens. A Combined Corner and Edge Detector. *Proceedings of the 4th Alvey Vision Conference*. pp. 147-151. 1988. Disponível em: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=88cdfbeb78058e0eb2613e79d1818c567f0920e2>
- Jiménez-Jiménez. Sergio Iván. Waldo Ojeda-Bustamante. Mariana de Jesús Marcial-Pablo. and Juan Enciso. Digital Terrain Models Generated with Low-Cost UAV Photogrammetry: Methodology and Accuracy. *ISPRS International Journal of Geo-Information*. v. 10. n. 5. 2021. <https://doi.org/10.3390/ijgi10050285>
- Janicka. J.; Rapinski. J. Outliers detection by Ransac algorithm in the transformation of 2d coordinate frames. *Boletim de Ciências Geodésicas*. v. 3. n.20. 2014. ISSN 1982-2170 <https://doi.org/10.1590/S1982-21702014000300035>
- Kucak A.; Yakar I.; Bilgi S.; Erol S.; Dervisoglu A. A Comparative Analysis of Speeded Up Robust Features (SURF) and Harris Algorithms in Point Cloud Generation. Proceedings 1st Intercontinental Geoinformation Days (IGD). 2020. Turquia
- Karami. E.; Prasad. S.; Shehata. M. Image Matching Using SIFT. SURF. BRIEF and ORB: Performance Comparison for Distorted Images. Proceedings: 2015 Newfoundland Electrical and Computer Engineering Conference. Canada. DOI:[10.48550/arXiv.1710.02726](https://doi.org/10.48550/arXiv.1710.02726).
- Lai. M. 2024. A study on drone-based detection and recognition of concrete surface cracks in tunnels using advanced imaging and machine learning techniques. *Advances in Operation Research and Production Management*.v. 3. 2024. <https://doi.org/10.54254/3029-0880/2024.19215>
- Lavezzi. G.; Ciarcià. M.; Won. K.; Tazav. M. A DIC-UAV based displacement measurement technique for bridge field testing. *Engineering Structures*. Volume 308. 2024. ISSN 0141-0296. <https://doi.org/10.1016/j.engstruct.2024.117951>.
- Li. D.; You. R.; Kaewunruen. S. Crack Propagation Assessment of Time-Dependent Concrete Degradation of Prestressed Concrete Sleepers. *Sustainability*. n. 14. 2022. <https://doi.org/10.3390/su14063217>
- Liang. H.; Lee. S.-C.; Bae. W.; Kim. J.; Seo. S. Towards UAVs in Construction: Advancements. Challenges. and Future Directions for Monitoring and Inspection. *Drones*. 7(3). 2023. <https://doi.org/10.3390/drones7030202>
- Ling. X.; Huang. X.; Zhang. Y. e Zhou. G. Matching Confidence Constrained Bundle Adjustment for Multi-View High-Resolution Satellite Images. *Remote Sens*. v.20. n.12. 2020. <https://doi.org/10.3390/rs12010020>
- Liu. B.; Yang. T.; Wu. X.; Wang. B.; Zhang. H.; Wu. Y. UAV imagery-based railroad station building inspection using hybrid learning architecture. *Measurement Science and Technology*. 35. 2024. DOI: <http://dx.doi.org/10.1088/1361-6501/ad4ab5>.
- Liu. G.; Luo. J.; Yang. Q.; Law. S.; He. C. Non-contact Structural Displacement Measurement using UAV and DIC with Non-coplanar Fixed Region of Interest. *Measurement*. Volume 242. Part B. 2025. ISSN 0263-2241. <https://doi.org/10.1016/j.measurement.2024.115936>.
- Marotta. G.S.; Silva. A.S.; Gonçalves. R. P.; Andrade. R. J. DE O.; Assis. L. C. de. Estimativa da precisão posicional utilizando ajustamento de observações clássico e livre. *Proceedings: XXIII Congresso Brasileiro de Cartografia*. Rio de Janeiro. Brasil. 2007. <https://doi.org/10.13140/2.1.3048.2884>
- Mccormick. N.; Lord. J. Digital Image Correlation. *Materials Today*. v.13. n.12. 2010. ISSN 1369-7021. [https://doi.org/10.1016/S1369-7021\(10\)70235-2](https://doi.org/10.1016/S1369-7021(10)70235-2).
- Mobasher. Textile fiber composites: Testing and mechanical behaviour. *Textile Fibre Composites in Civil Engineering*. Editor(s): Thanasis Triantafillou. Woodhead Publishing. 2016. Pages 101-150. ISBN 9781782424468. <https://doi.org/10.1016/B978-1-78242-446-8.00006-9>.
- Mohammed.Y.;Uddin. N.; Tan. C. SHI. Z. Crack Detection using Faster R-CNN and Point Feature Matching. *Civil Enginnering Research Journal*. v. 10. n.3. 2020. <https://doi.org/10.19080/CERJ.2020.10.555790>
- Pérez-Sinticala. C.; Janvier. R.; Brunetaud. X.; Treuillet. S.; Aguilar. R.; E Castañeda. B.Evaluation of Primitive Extraction

- Methods from Point Clouds of Cultural Heritage Buildings: An Interdisciplinary Approach. In: Aguilar, R.; Torrealva, D.; Moreira, S.; Pando, M. A.; Ramos, L. F. (eds) Structural Analysis of Historical Constructions. RILEM Bookseries. v. 18. Springer. Cham. [https://doi.org/10.1007/978-3-319-99441-3\\_250](https://doi.org/10.1007/978-3-319-99441-3_250)
- Qiao, W.; Zhang, H.; Zhu, F.; Wu, Q. A Crack Identification Method for Concrete Structures Using Improved U-Net Convolutional Neural Networks. *Mathematical Problems in Engineering*. 2021. Wiley Online Library. <https://doi.org/10.1155/2021/6654996>
- Shah, F.M.; Shah, Z. M.; Janjua, G.; Zhang, Y. X. Crack Detection on Civil Structure Using Efficient Image Processing and Computer Vision Approach. *Proceedings: Advances in Science and Engineering Technology International Conferences (ASET)*. 2024. <https://doi.org/10.1109/ASET60340.2024.10708670>
- UFU. Universidade Federal de Uberlândia. Pró-reitoria de Planejamento. *Anuário 2023*. Disponível em: <https://prolad.ufu.br/central-de-conteudos/documentos/2024/06/anuario-2023>
- Zhang, T.; Qin, L.; Zou, Q.; Zhang, L.; Wang, R.; E, Zhang, H. 2024. CrackScopeNet: A Lightweight Neural Network for Rapid Cracks Detection on Resource-Constrained Drone Platforms. *Drones*. v.9. n.8. 2024. <https://doi.org/10.3390/drones8090417>
- Zhang, Q.; Shi, B.; e, Xu, H. Least Squares Consensus for Matching Local Features. *Information*. n. 10. 2019. <https://doi.org/10.3390/info10090275>
- Zhou, K.; Lei, D.; He, J.; Zhang, P.; Bai, P.; E, Zhu, F. Single micro-damage identification and evaluation in concrete using digital image correlation technology and wavelet analysis. *Construction and Building Materials*. v. 267. 2021. <https://doi.org/10.1016/j.conbuildmat.2020.120951>
- Wang, Y.; Huang, H.; Dong, Z.; Wu, M. Modified RANSAC for Sift-Based InSAR Image Registration. *Progress In Electromagnetics Research*. v. 37. 2014. <https://doi.org/10.2528/PIERM14042202>
- Worachairungreung, M.; Kulpanich, N.; Thanakunwutthirot, N.; Hemwan, P. Monitoring Agricultural Land Loss by Analyzing Changes in Land Use and Land Cover. *Emerging Science Journal*. v.8. n.2. 2024. DOI: <http://dx.doi.org/10.28991/ESJ-2024-08-02-020>