Uso do OpenCV na Identificação de Pisos Táteis em Ambientes Internos

Cristiano da Silva Andrade[1], Carlos Alberto Santana dos Santos[1], Luiz Eduardo Andrade de Oliveira[1], Stephanie Kamarry Alves de Sousa[1], Fábio Luiz Sá Prudente[2]

[1]Instituto Federal de Sergipe (IFS)
Lagarto, SE, Brazil

[2]Instituto Federal de Sergipe (IFS)
Aracaju, SE, Brazil

cristiano.andrade@academico.ifs.edu.br
carlos.santos0841@academico.ifs.edu.br
luiz.oliveira077@academico.ifs.edu.br
stephanie.sousa@ifs.edu.br, fabio.prudente@ifs.edu.br

Abstract. *This paper presents the development and experimental evaluation of a real-time system for detecting tactile paving in indoor environments using OpenCV. The method combines color segmentation in the Hue, Saturation and Value (HSV) space, morphological filtering and contour analysis. In six controlled positive conditions, with tactile paving visible in every frame, the system detected all 4,368 analyzed frames. This result represents a 100% detection rate for the positive samples, not the general precision of the system. The weighted mean processing time was 2.04 ms per frame. The effective rate remained limited by the camera capture at about 29.98 frames per second. Tests with negative scenes and real environments are still required.*

Resumo. *Este artigo apresenta o desenvolvimento e a avaliação experimental de um sistema em tempo real para detectar pisos táteis em ambientes internos com OpenCV. O método combina segmentação por cor no espaço de Matiz, Saturação e Valor (HSV), filtragem morfológica e análise de contornos. Nas seis condições positivas controladas, com piso tátil visível em todos os quadros, o sistema detectou os 4.368 quadros analisados. Esse resultado corresponde a uma taxa de detecção de 100% nas amostras positivas, não à precisão geral do sistema. O tempo médio ponderado de processamento foi de 2,04 ms por quadro. A taxa efetiva permaneceu limitada pela captura da câmera, próxima de 29,98 quadros por segundo. Ainda são necessários testes com cenas negativas e ambientes reais.*

1. Introdução

A acessibilidade para pessoas com deficiência visual é assegurada pela Lei Brasileira de Inclusão, Lei n. 13.146/2015 [BRASIL 2015], e normatizada pela Associação Brasileira de Normas Técnicas (ABNT), por meio da NBR 9050:2020 [ABNT 2020]. Dados do Censo Demográfico 2022, publicados em 2025 pelo Instituto Brasileiro de Geografia e Estatística (IBGE), apontam que cerca de 7,9 milhões de pessoas com 2 anos ou mais

tinham dificuldade permanente para enxergar, mesmo usando óculos ou lentes de contato [IBGE 2025]. Esse número mostra a dimensão social dos desafios de mobilidade e autonomia. Nesse cenário, o piso tátil ocupa papel central entre os recursos de acessibilidade, pois orienta e alerta pessoas com deficiência visual durante o deslocamento em edificações, espaços coletivos, vias e logradouros públicos [ABNT 2020].

A detecção automática de pisos táteis pode apoiar tecnologias assistivas, como bengalas eletrônicas, robôs guia e navegação embarcada em cadeiras de rodas motorizadas [Kassim et al. 2018]. Contudo, a identificação em ambientes internos enfrenta variações de iluminação, reflexos em pisos polidos, oclusão por móveis ou pessoas e diferenças nas tonalidades dos revestimentos.

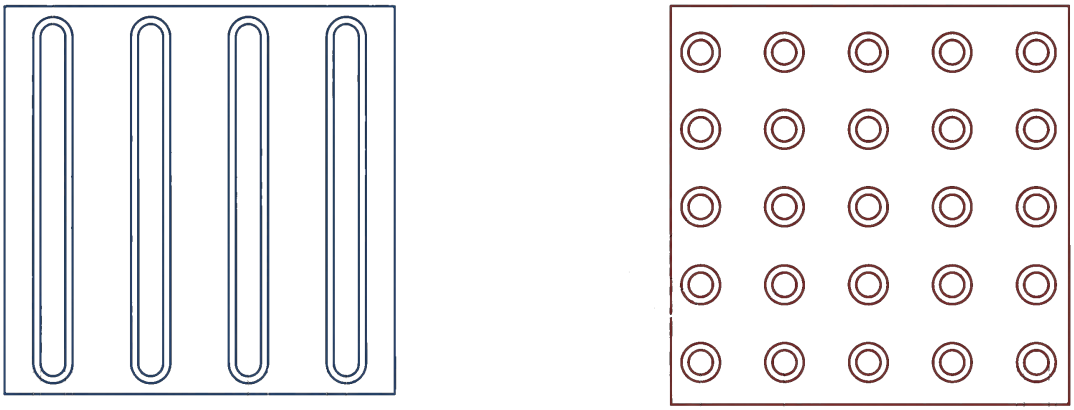
O sistema foi desenvolvido com a Open Source Computer Vision Library (OpenCV), biblioteca que oferece rotinas de processamento de imagem capazes de operar em tempo real. Essas rotinas podem ser executadas sem modelos de aprendizado profundo ou uma unidade de processamento gráfico (GPU) [Bradski and Kaehler 2008].

O objetivo deste artigo é apresentar o desenvolvimento, a implementação e a avaliação de um sistema baseado em OpenCV para identificar pisos táteis em ambientes internos. A solução utiliza segmentação por cor no espaço HSV, filtragem morfológica e análise de contornos.

2. Fundamentação Teórica

2.1. Piso Tátil

O piso tátil é um elemento de pavimentação com textura superficial diferenciada, usado para orientar e alertar pessoas com deficiência visual. A ABNT NBR 9050:2020 define dois tipos principais [ABNT 2020]. O piso direcional apresenta relevos lineares paralelos que indicam o percurso seguro. O piso de alerta possui relevos em forma de troncos de cone e sinaliza riscos, mudanças de direção, cruzamentos ou o fim de um percurso. A Figura 1 apresenta a geometria dos dois tipos.



(a) Direcional (b) Alerta

Figura 1. Geometria dos pisos táteis: (a) direcional, com relevos lineares; (b) de alerta, com relevos em troncos de cone.

A NBR 9050:2020 indica que o piso tátil deve apresentar contraste com o piso adjacente. O amarelo é comum por oferecer bom contraste visual, mas também há instalações com outras cores. Este estudo utilizou uma amostra azul para o piso direcional e uma vermelha para o piso de alerta, conforme o material disponível no ambiente de teste.

A instalação de piso tátil em edificações públicas e espaços de uso coletivo é prevista pela NBR 9050:2020 e amparada pela Lei Brasileira de Inclusão [BRASIL 2015, ABNT 2020]. Em corredores, halls, salas de espera, escolas e universidades, esse recurso ajuda a manter a continuidade segura dos trajetos.

2.2. OpenCV

O OpenCV é uma biblioteca de código aberto usada em linguagens como Python, C++ e Java. Ela reúne algoritmos para diversas tarefas de visão computacional [Bradski and Kaehler 2008, Howse and Minichino 2020]. Neste trabalho, a biblioteca segmenta regiões por cor e extrai seus contornos. Os contornos descrevem os objetos por meio da área, da posição e da caixa delimitadora.

2.3. Espaço de Cor HSV

Imagens digitais costumam ser representadas nos espaços azul, verde e vermelho (BGR, do inglês *Blue, Green and Red*) ou vermelho, verde e azul (RGB, do inglês *Red, Green and Blue*). Nesses espaços, a informação de cor e brilho está distribuída entre três canais. Quando a iluminação muda, os canais também variam, o que dificulta isolar uma cor de forma estável.

O espaço HSV separa essas informações. A Matiz representa o tom da cor, a Saturação descreve sua intensidade e o Valor representa o brilho. Essa separação permite definir intervalos de cor menos sensíveis a pequenas mudanças de iluminação. Uma alteração maior no ambiente ou na câmera ainda pode exigir nova calibração [Howse and Minichino 2020]. A Figura 2 apresenta os três componentes e destaca as faixas de matiz usadas no experimento.

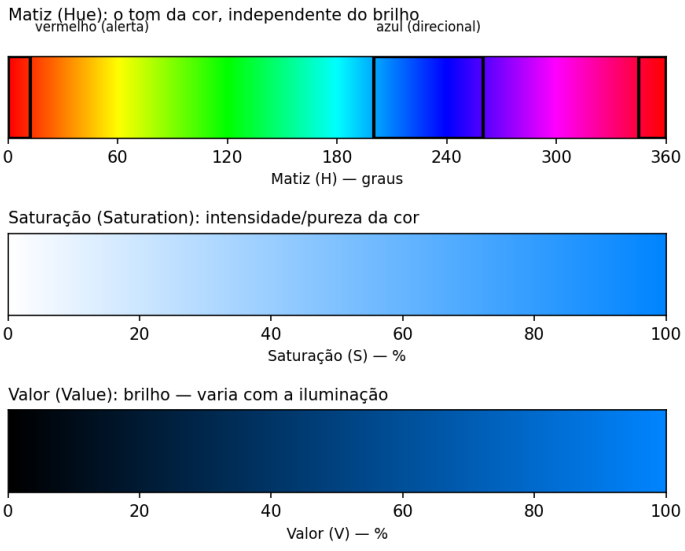


Figura 2. Componentes do espaço HSV e faixas de matiz usadas na calibração das cores azul e vermelha.

3. Trabalhos Relacionados

Abordagens clássicas de processamento de imagem utilizam operações como segmentação por cor, limiarização e detecção de contornos. Um método para detectar pisos táteis em calçadas identificou a variação da iluminação natural como o principal fator limitante [Ghilardi et al. 2016]. Em ambientes internos, a iluminação artificial não uniforme produz um problema semelhante.

Uma limiarização dinâmica no espaço HSV foi desenvolvida para acompanhar mudanças na luz solar [Ito et al. 2021]. O presente trabalho usa limiares fixos porque o ambiente interno apresentou iluminação artificial estável. A calibração foi realizada uma vez antes dos testes. Uma mudança de câmera, iluminação ou ambiente exige nova calibração manual. Em paralelo, uma revisão da literatura sobre métodos de navegação para pessoas com deficiência visual apontou a escassez de avaliações em ambientes internos [Kassim et al. 2018].

Métodos com aprendizado profundo alcançam bons resultados em cenários com maior variação visual, mas demandam dados anotados e maior capacidade computacional [Aktaş et al. 2020]. Modelos baseados em You Only Look Once (YOLO) também apresentaram bons resultados [Zhang 2024, Karakan 2024]. A implantação desses modelos em dispositivos embarcados pode exigir mais recursos. O aprendizado profundo não foi usado neste estudo, cujo foco é uma solução leve, calibrada para um ambiente específico e executada em uma unidade central de processamento (CPU). Em uma linha semelhante à adotada aqui, outro estudo investigou uma segmentação rápida voltada à redução de ruídos, reforçando a viabilidade de abordagens leves [Niu and Bao 2024].

No contexto brasileiro, um sistema de navegação para cadeira de rodas motorizada foi desenvolvido com base em pisos táteis [Soares et al. 2021]. Outro estudo brasileiro utilizou um sensor Microsoft Kinect e rastreamento esquelético na interação humano-robô. O método combinou a técnica *Wizard of Oz*, na qual um operador oculto simula as respostas do sistema, com falhas controladas de interação. Esse procedimento estimulou a produção de gestos espontâneos, posteriormente avaliados quanto à adequação ao controle de drones [dos Santos et al. 2026]. Embora trate de outro problema, o trabalho mostra o uso de sensores visuais e métodos centrados no usuário no desenvolvimento de interfaces naturais para sistemas robóticos. Já em termos de bases de dados, o Tenji10K é um conjunto público voltado a cenários externos e padrões diferentes dos avaliados neste trabalho [Takano et al. 2024].

4. Metodologia

4.1. Ambiente e Equipamento

Os experimentos foram conduzidos em um ambiente interno com iluminação fluorescente. A câmera foi configurada para capturar imagens com resolução de 640×480 pixels. Para viabilizar essa captura, os testes foram executados em um computador com processador AMD Ryzen 5 4600G, 16 GB de memória RAM DDR4 3200 MHz, GPU NVIDIA RTX 3050 e Windows 11 Pro. A GPU não participou do processamento. O sistema foi implementado em Python 3.10 com OpenCV-Python 4.11.0.

Paralelamente à captura, os dados de cada quadro foram armazenados em um arquivo de valores separados por vírgula (CSV, do inglês *Comma-Separated Values*). O

registro incluiu o tempo de processamento medido com temporização de alta resolução. A taxa equivalente de quadros por segundo (FPS) considera apenas o tempo do algoritmo. A taxa real de captura foi calculada a partir dos horários registrados no arquivo.

Foram usadas duas amostras de piso tátil sobre um fundo neutro. A amostra direcional possuía linhas paralelas e cor azul. A amostra de alerta possuía troncos de cone e cor vermelha. A câmera ficou fixa acima do piso durante toda a coleta.

4.2. Fluxo de Detecção

O fluxo apresentado na Figura 3 é repetido para cada quadro. A imagem é capturada e convertida do espaço BGR para HSV. Em seguida, o sistema aplica a limiarização por cor e cria uma máscara binária. A máscara destaca os pixels que pertencem às faixas calibradas para o azul ou o vermelho.

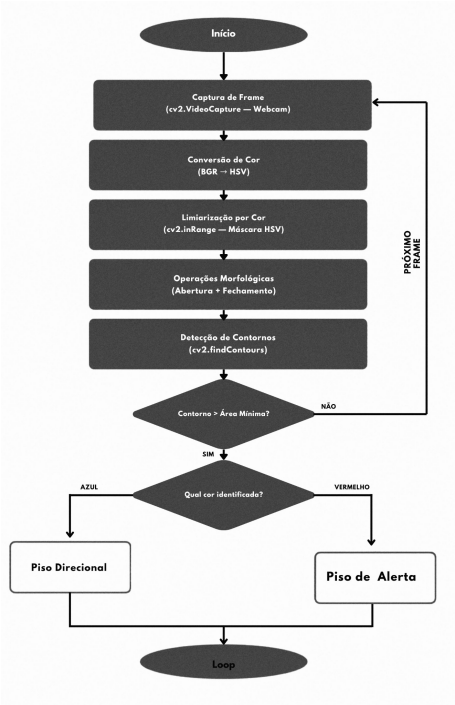


Figura 3. Fluxo de detecção de pisos táteis com OpenCV.

As operações morfológicas de abertura e fechamento tratam pequenos ruídos e falhas. A abertura remove pontos isolados. O fechamento preenche pequenas lacunas internas. Os parâmetros fixos, apresentados na Tabela 1, foram definidos de modo que as faixas de matiz não se sobrepusessem, evitando ambiguidade na classificação.

Após o tratamento, o sistema detecta os contornos. Cada contorno é comparado ao limiar de área mínima. Manchas pequenas são descartadas. Quando há um contorno válido, o algoritmo seleciona o de maior área e calcula sua caixa delimitadora. A faixa de cor define a classificação: azul para o piso direcional e vermelho para o piso de alerta. O ciclo é reiniciado no quadro seguinte.

4.3. Protocolo de Coleta de Dados

Foram definidas seis condições que combinam os dois tipos de piso e três níveis de sombra: sem sombra, sombra sobre metade do piso e sombra sobre todo o piso, produzida por

Tabela 1. Parâmetros fixos de segmentação e tratamento morfológico.

Parâmetro	Valor adotado
HSV direcional, azul	Inferior [100, 80, 60] e superior [130, 255, 255]
HSV de alerta, vermelho	Inferior [160, 80, 60] e superior [179, 255, 255]
Kernel morfológico	5×5
Operações morfológicas	Uma abertura e um fechamento
Área mínima direcional	500 px^2
Área mínima de alerta	1.000 px^2

meio de um anteparo colocado entre a lâmpada e o piso. A câmera permaneceu fixa em um ponto acima da amostra, e a captura continuou até o encerramento manual.

O sistema registrou o resultado da detecção, a classe identificada, o tempo de processamento, o FPS equivalente, as coordenadas da caixa delimitadora, a área do contorno e o percentual de cobertura. A referência verdadeira, também chamada de *ground truth*, foi definida manualmente após a coleta. Ela considerou a presença e o tipo do piso em cada quadro.

4.4. Métricas de Avaliação

Cada quadro pode ser classificado como verdadeiro positivo (VP), falso positivo (FP), falso negativo (FN) ou verdadeiro negativo (VN). O VP ocorre quando o sistema detecta um piso presente. O FP ocorre quando há detecção sem piso. O FN representa um piso presente que não foi detectado. O VN ocorre quando não há piso nem detecção. Precisão, revocação e medida F1 são definidas pelas Equações 1 a 3.

$$\text{Precisão} = \frac{VP}{VP + FP} \tag{1}$$

$$\text{Revocação} = \frac{VP}{VP + FN} \tag{2}$$

$$F1 = 2 \times \frac{\text{Precisão} \times \text{Revocação}}{\text{Precisão} + \text{Revocação}} \tag{3}$$

Essas métricas são usadas em estudos sobre detecção de pisos táteis [Aktaş et al. 2020, Karakan 2024]. O protocolo quantitativo deste trabalho contém somente quadros positivos. Nesse conjunto, é possível medir a revocação e a classificação por tipo de piso. A precisão e a medida F1 dependem de uma avaliação padronizada de falsos positivos em cenas negativas. Por isso, elas não são apresentadas como medidas gerais do sistema.

A cobertura média corresponde à razão entre a área do contorno e a área total do quadro, expressa em porcentagem. Ela indica quanto da imagem foi ocupado pela região segmentada. Não representa uma medida de acerto.

5. Resultados e Discussão

5.1. Calibração e Condições de Teste

Os limiares HSV foram calibrados manualmente no ambiente de teste, com a câmera já na posição definitiva e a iluminação fluorescente ligada. Para isso, regiões das amostras azul e vermelha foram usadas para ajustar os limites de Matiz, Saturação e Valor, intervalos que foram mantidos durante toda a coleta.

A Tabela 2 apresenta o número de quadros, as detecções, a taxa de detecção positiva, o tempo médio de processamento, o FPS de processamento e a cobertura média. Todas as condições continham piso tátil. Os resultados medem a capacidade de detectar e classificar as amostras presentes. Eles não representam o comportamento do sistema em cenas sem piso.

Tabela 2. Condições de teste e resultados nas amostras positivas.

Cond.	Tipo	Sombra	Quadros	Detect.	Taxa (%)	Tempo (ms)	FPS proc.	Cob. (%)
D01	Direcional	Sem sombra	574	574	100	2,87	397,4	0,75
D02	Direcional	Metade	835	835	100	1,95	524,8	9,11
D03	Direcional	Total	899	899	100	1,99	518,6	21,37
E01	Alerta	Sem sombra	628	628	100	1,83	560,5	23,18
E02	Alerta	Metade	710	710	100	1,97	522,0	10,48
E03	Alerta	Total	722	722	100	1,80	567,8	22,65
Total			**4.368**	**4.368**	**100**	**2,04**	**490,2**	**n.a.**

O tempo médio ponderado foi de 2,04 ms por quadro. Seu inverso corresponde a uma capacidade de processamento próxima de 490,2 FPS. Esse valor mede apenas o tempo gasto pelo algoritmo depois que a imagem chega ao computador. A câmera capturou cerca de 29,98 FPS. Assim, a taxa efetiva do sistema completo foi próxima de 29,98 FPS.

O algoritmo não gera vários resultados para o mesmo quadro. Cada quadro capturado é processado uma vez. Como o processamento termina antes da chegada do próximo quadro, o sistema permanece livre até receber uma nova imagem. O valor de 490,2 FPS mostra que o algoritmo tem margem de processamento, não que a câmera produza 490,2 imagens por segundo.

A Tabela 3 mostra que não houve troca entre as duas classes. Ela resume somente as amostras positivas e não constitui uma matriz de confusão completa.

Tabela 3. Classificação por tipo de piso nas amostras positivas.

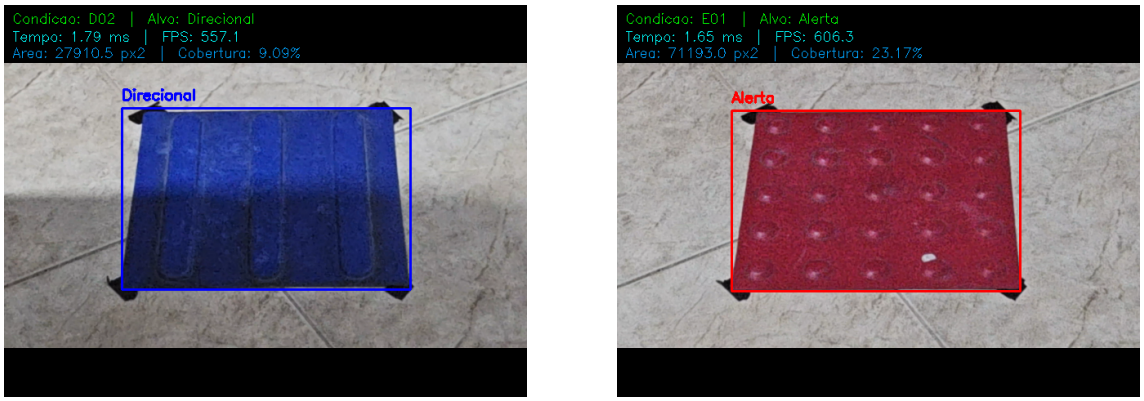
Classe real	Direcional detectado	Alerta detectado	Não detectado
Direcional	2.308	0	0
Alerta	0	2.060	0

Conforme visto na Tabela 2, os totais de quadros por condição diferem entre si porque a captura foi encerrada manualmente. Uma avaliação futura deverá usar a mesma duração ou o mesmo número de quadros em todas as condições.

O resultado deve ser interpretado dentro do cenário controlado. As amostras foram colocadas isoladamente sobre um fundo neutro. A câmera ficou fixa e a iluminação foi

mantida. Não havia outros objetos com as cores calibradas no campo de visão. Essas condições facilitaram a separação entre as amostras e o fundo.

A Figura 4 apresenta duas detecções registradas durante os testes. A primeira mostra o piso direcional com sombra parcial. A segunda mostra o piso de alerta sem sombra.



(a) Direcional com sombra parcial (b) Alerta sem sombra

Figura 4. Exemplos de detecção em tempo real nas condições controladas.

5.2. Métricas Globais

Nos 4.368 quadros positivos, o sistema registrou 4.368 verdadeiros positivos e nenhum falso negativo. Como indicado na Tabela 3, o sistema também não confundiu as classes, resultado consistente com a revocação de 100% obtida. Esse percentual descreve a detecção nas amostras positivas do protocolo controlado. Ele não deve ser interpretado como precisão geral.

As cenas negativas não seguiram o mesmo protocolo quantitativo. Por esse motivo, não há uma estimativa completa de falsos positivos e verdadeiros negativos. A precisão e a medida F1 não podem ser generalizadas a partir desta coleta. A cobertura variou entre as condições, mas não impediu a detecção das amostras avaliadas.

5.3. Limitações Identificadas

Os testes foram realizados com amostras isoladas, câmera fixa e iluminação controlada. As cenas negativas foram apenas qualitativas. Os limiares HSV foram calibrados para uma câmera e um ambiente específicos. Uma mudança de local pode exigir nova calibração. Também não foram avaliados oclusões por pessoas ou móveis, fundos coloridos complexos e o piso amarelo comum em instalações que seguem a norma.

6. Conclusão

Este artigo demonstrou a viabilidade de um sistema leve baseado em OpenCV, combinando segmentação HSV, filtragem morfológica e análise de contornos para distinguir pisos direcionais de pisos de alerta.

O sistema detectou os 4.368 quadros positivos avaliados nas seis condições controladas. A revocação nesse conjunto foi de 100%. Esse resultado não representa a precisão geral do sistema, pois a coleta quantitativa não incluiu cenas negativas. O tempo

médio ponderado de processamento foi de 2,04 ms por quadro. A capacidade calculada de 490,2 FPS se refere apenas ao algoritmo. A taxa efetiva ficou limitada pela câmera, que capturou cerca de 29,98 FPS.

Os resultados mostram que uma abordagem clássica pode operar em tempo real usando apenas a CPU. Novos testes devem incluir corredores em uso, piso amarelo, oclusões, reflexos, objetos com cores semelhantes e cenas sem piso tátil. Esses testes permitirão medir falsos positivos e verificar o desempenho em situações mais próximas do uso cotidiano.

Referências

ABNT (2020). Nbr 9050: acessibilidade a edificações, mobiliário, espaços e equipamentos urbanos. Technical report, Associação Brasileira de Normas Técnicas, Rio de Janeiro.

Aktaş, A., Doğan, B., and Demir, O. (2020). Tactile paving surface detection with deep learning methods. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(3):1685–1700.

Bradski, G. and Kaehler, A. (2008). *Learning OpenCV: Computer Vision with the OpenCV Library*. O'Reilly Media, Sebastopol, CA.

BRASIL (2015). Lei n. 13.146, de 6 de julho de 2015: Lei brasileira de inclusão da pessoa com deficiência. `https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2015/lei/l13146.htm`.

dos Santos, C. A. S., Santos, J. P. S. S., de Sousa, S. K. A., Santos, P. C., Freire, E. O., and Givigi, S. N. (2026). Eliciting intuitive gestures in drones via controlled frustration: A multidisciplinary study. In *2026 Brazilian Conference on Robotics (CROS)*, pages 519–524. IEEE.

Ghilardi, M. C., Macedo, R. C. O., and Manssour, I. H. (2016). A new approach for automatic detection of tactile paving surfaces in sidewalks. *Procedia Computer Science*, 80:662–672.

Howse, J. and Minichino, J. (2020). *Learning OpenCV 4 Computer Vision with Python 3*. Packt Publishing, Birmingham, 3 edition.

IBGE (2025). Censo demográfico 2022: pessoas com deficiência e pessoas diagnosticadas com transtorno do espectro autista: resultados preliminares da amostra. Technical report, Instituto Brasileiro de Geografia e Estatística, Rio de Janeiro.

Ito, Y., Premachandra, C., Sumathipala, S., Premachandra, H. W. H., and Sudantha, B. S. (2021). Tactile paving detection by dynamic thresholding based on hsv space analysis for developing a walking support system. *IEEE Access*, 9:20358–20367.

Karakan, A. (2024). A new approach to automatic detection of tactile coating surfaces with deep learning. *Bitlis Eren University Journal of Science*, 13(4):885–895.

Kassim, A. B. M., Yasuno, T., Suzuki, H., Aras, M. S. M., Shukor, A. Z., Jaafar, H. I., and Jafar, F. A. (2018). Vision-based tactile paving detection method in navigation systems for visually impaired persons. In *Advances in Human and Machine Navigation Systems*. IntechOpen.

Niu, L. and Bao, H. (2024). Fast tactile paving segmentation model based on reparameterized structure. In *Proc. 2024 Int. Conf. on Generative Artificial Intelligence and Information Security (GAIIS '24)*. ACM.

Soares, M. O. et al. (2021). Navegação autônoma de cadeira de rodas motorizada com base nos segmentos de pisos táteis. Instituto Federal de Sergipe / UFCG.

Takano, T., Nakane, T., Yu, J., and Zhang, C. (2024). Tactile paving detection and tracking using tenji10k dataset. *IEEJ Transactions on Electrical and Electronic Engineering*, 19(10):1661–1672.

Zhang, Z. (2024). Research on object detection based on yolo and its application in tactile paving recognition. *Highlights in Science, Engineering and Technology*, 122:64–76.