

Desenvolvimento de uma Solução Baseada em Visão Computacional para Contagem em Tempo Real de Garrafas Tampadas em Linhas de Produção Industrial

Clemilton B. de S. Furtado
Curso de Engenharia Elétrica

Universidade do Estado do Amazonas
Manaus, Brasil

cbdsf.eng20@uea.edu.br

Rubens de A. Fernandes
Escola Superior de Tecnologia

Universidade do Estado do Amazonas
Manaus, Brasil

rfernandes@uea.edu.br

Wheidima C. de Melo
Escola Superior de Tecnologia

Universidade do Estado do Amazonas
Manaus, Brasil

wmelo@uea.edu.br

Resumo—Este artigo apresenta o desenvolvimento e a avaliação de um sistema baseado em visão computacional para contagem em tempo real de garrafas tampadas em uma linha de produção industrial de bebidas. A solução proposta visa substituir métodos tradicionais baseados em sensores ópticos, os quais são suscetíveis a imprecisões de contagem devido a desalinhamentos mecânicos ou problemas de configuração. O sistema utiliza uma webcam Logitech C920s conectada a uma placa Rock Pi S e aplica técnicas tradicionais de processamento de imagem — como conversão de espaço de cor, segmentação baseada em HSV e limiarização — para detectar e contar garrafas em movimento. Uma região de interesse (ROI) específica é definida para isolar apenas a parte relevante da imagem. Todo o sistema foi implementado em Python utilizando OpenCV, garantindo facilidade de replicação e escalabilidade. Testes de campo foram realizados em um ambiente industrial real, e o sistema obteve uma taxa de acerto elevada, com F1-score de 99,8%. Os resultados demonstram a viabilidade de integrar tecnologias de visão de baixo custo e acessíveis para melhorar o controle de qualidade, reduzir desperdícios e aumentar a confiabilidade nos processos produtivos. A solução oferece uma alternativa eficiente, escalável e de baixa complexidade para aprimorar a eficiência operacional em ambientes fabris.

Index Terms—Visão Computacional, Automação Industrial, Processamento de Imagens, Contagem de Garrafas, Limiarização, Segmentação HSV.

I. INTRODUÇÃO

O controle de qualidade é um fator essencial para manter a competitividade e a confiabilidade dos sistemas industriais de produção [1]. Em linhas de envase de bebidas, discrepâncias entre a produção real e os dados coletados por métodos tradicionais de contagem — como sensores ópticos — podem ocasionar ineficiências operacionais, divergências de estoque e insatisfação do cliente. Tais discrepâncias geralmente decorrem de desalinhamentos mecânicos, falhas na configuração dos sensores ou limitações na lógica de detecção.

Com o objetivo de mitigar esses problemas, a visão computacional tem se destacado como uma alternativa promissora, ao permitir a contagem automatizada e precisa de objetos

por meio da análise de imagens em tempo real [2]. Embora soluções baseadas em aprendizado profundo [3], como YOLO [4] e MobileNet [5], ofereçam desempenho robusto, elas exigem recursos computacionais elevados e hardware especializado (por exemplo, GPUs [6]), o que pode ser inviável em ambientes industriais de baixo custo.

Este trabalho propõe um sistema de contagem em tempo real de garrafas tampadas em um ambiente de produção industrial, utilizando uma solução baseada em visão computacional e processamento digital de imagens atrelada a um hardware de baixo custo e fácil acesso. O sistema é composto por uma webcam Logitech C920s [7] e uma plataforma Rock Pi S [8]. Em vez de depender de inferência por redes neurais profundas [9], a solução emprega técnicas tradicionais de processamento de imagem [10] — como segmentação por cor em HSV, limiarização e análise de contornos — para alcançar alta precisão com baixo custo computacional.

O objetivo desta pesquisa é validar a viabilidade da implantação desse sistema em ambientes reais de fábrica, com foco em aprimorar o monitoramento da produção e reduzir erros de contagem. O protótipo foi testado em condições reais e avaliado por meio de métricas como precisão, revocação e F1-score [11].

Os resultados demonstram que técnicas tradicionais de processamento de imagem, quando devidamente otimizadas e combinadas com uma região de interesse bem definida, podem oferecer desempenho confiável e preciso para tarefas de contagem em ambientes industriais, sem a necessidade de hardware avançado.

II. METODOLOGIA

O sistema proposto consiste em uma arquitetura baseada em visão computacional para detecção e contagem de garrafas tampadas em uma linha de produção de bebidas. O conjunto de hardware inclui uma webcam Logitech C920s para captura de imagens e uma placa Rock Pi S para processamento em tempo real. A pilha de software foi implementada em Python [12],

utilizando as bibliotecas OpenCV (Open Source Computer Vision Library) [13] e NumPy [14].

A. Hardware e Software Utilizados

O sistema foi concebido para operar integralmente em uma Rock Pi S, eliminando a necessidade de aceleração por GPU ou dependência de servidores externos. Essa abordagem garante portabilidade e baixo consumo de energia para a aplicação.

No desenvolvimento do projeto, a linguagem de programação Python foi utilizada como base. A biblioteca NumPy desempenhou um papel crucial na definição dos limites de cor para a máscara de processamento de imagens e na contagem de pixels que satisfazem os critérios estabelecidos, onde essa funcionalidade foi essencial para a análise e manipulação dos dados. Paralelamente, a biblioteca OpenCV foi fundamental para a captura de vídeo via câmera, a leitura de quadros (frames) e a execução de operações de processamento digital de imagens.

Os componentes de hardware e software utilizados estão detalhados a seguir:

- **ROCK Pi S:** Rockchip RK3308B SoC com CPU quad-core ARM Cortex-A35 de até 1,0 GHz, 256 MB RAM DDR3. [8]
- **Câmera:** Logitech C920s (resolução de 1080p a 30 FPS) [7]
- **Software:** Python 3.8, OpenCV 4.5, NumPy

B. Arquitetura do Sistema Proposto

A arquitetura do sistema proposto, ilustrada na Figura 1, foi desenvolvida para monitorar e processar garrafas em uma linha de produção, especificamente após a estação de tampagem. Para tal, uma câmera é estrategicamente posicionada para focar em uma Região de Interesse (ROI) predefinida [10]. Essa ROI foi determinada empiricamente, com base em observações práticas da linha de produção, de modo a capturar de forma eficaz a área onde as garrafas aparecem após o processo de tampagem. A definição estática dessa ROI é crucial, pois minimiza a interferência de ruídos ambientais no fundo da imagem e otimiza significativamente o tempo de processamento, direcionando os recursos computacionais apenas para a área relevante.

Após a captura dos quadros de vídeo, o fluxo de processamento inicia-se com a conversão do espaço de cor BGR (Azul, Verde, Vermelho) [10] para HSV (Matiz, Saturação, Valor) [10]. Essa conversão é fundamental, pois o espaço de cor HSV é inerentemente mais robusto a variações de iluminação, facilitando a segmentação de objetos por cor. Subsequentemente, é aplicada uma técnica de limiarização (thresholding), uma técnica que permite isolar as tampas das garrafas com base em seus atributos de cor no espaço HSV. O resultado dessa etapa é uma máscara binária, onde os pixels brancos indicam a presença de uma tampa, enquanto os pixels pretos representam o fundo ou outras partes da imagem que não correspondem aos critérios de cor da tampa. Essa máscara




Fig. 1. Arquitetura do sistema, ilustrando a integração entre a câmera, o Rock Pi S e o fluxo de processamento para contagem em tempo real.

binária serve como base para as etapas subsequentes de análise e contagem.

C. Fluxo Geral de Execução

A lógica de funcionamento do sistema foi projetada para operar de forma contínua, autônoma e com tolerância a falhas em um ambiente industrial. A Figura 2 apresenta o fluxograma geral das etapas executadas desde a inicialização até a apresentação final das informações.




Fig. 2. Fluxograma geral do sistema de visão computacional para contagem de garrafas.

O processo se inicia com a execução do código principal e a tentativa de inicialização da câmera. O sistema realiza, nesse momento, uma verificação automática para assegurar que o

dispositivo de captura de vídeo está funcionando corretamente. Essa validação evita o prosseguimento do processo em casos de falha de conexão, ausência de sinal ou problemas de driver, promovendo maior confiabilidade.

Uma vez validado o funcionamento da câmera, o sistema entra em um ciclo de processamento contínuo. Em cada iteração, uma nova imagem é capturada em tempo real, convertida para um espaço de cor adequado (HSV), e processada digitalmente para destacar as regiões de interesse. As informações extraídas são então analisadas para identificação de tampas e posterior contagem de garrafas.

A cada contagem validada, o sistema atualiza uma interface de visualização com os dados processados. Esse resultado pode ser exibido localmente ou transmitido para um sistema de monitoramento externo, conforme a necessidade da aplicação. O fluxo é repetido continuamente até que o processo seja interrompido manualmente ou ocorra uma falha de hardware.

D. Processamento de Imagem e Estratégia de Contagem

Após a captura de cada quadro pela câmera, a imagem é convertida do espaço de cores BGR, padrão da biblioteca OpenCV, para o modelo HSV. Essa conversão facilita a segmentação de objetos com base em características de cor, pois separa as componentes de tonalidade, saturação e brilho, tornando o sistema mais robusto a variações de iluminação.

Com a imagem já convertida para o modelo HSV, aplica-se uma técnica de limiarização, na qual são definidos intervalos mínimos e máximos para os valores de cada componente de cor. Esses limites foram definidos de forma empírica, por meio de testes em ambiente real, e têm como objetivo isolar visualmente apenas as tampas das garrafas. O resultado desse processo é uma imagem binária, onde as regiões que se enquadram no intervalo especificado são destacadas, e o restante da imagem é descartado.

Em seguida, define-se uma ROI sobre a imagem processada. Essa região foi configurada de acordo com a posição em que as garrafas tampadas aparecem no vídeo. A partir dessa área, realiza-se a contagem de pixels brancos, que representam as tampas das garrafas detectadas. A Figura 3 ilustra a diferença entre a imagem original capturada pela câmera e sua correspondente versão binarizada após o processamento de imagem.



Fig. 3. Exemplo de imagem original e correspondente máscara binária obtida por limiarização em HSV.

Conforme a Figura 4, com base na quantidade de pixels detectados dentro da ROI e sua variação ao longo do tempo, o sistema determina se houve a passagem de um novo objeto. Para evitar a contagem repetida de um mesmo objeto, é adotada uma estratégia baseada em detecção entre quadros consecutivos. A cada novo frame, o sistema compara a quantidade de pixels brancos com os valores observados nos quadros anteriores. A contagem só é incrementada quando há um aumento significativo e contínuo nos pixels detectados, seguido por uma redução consistente, o que indica a entrada e a saída de um objeto da ROI.

Durante os testes, foi identificado que uma garrafa tampada corretamente gerava, em média, valores superiores a 1.500 pixels brancos dentro da ROI. Portanto, o sistema foi calibrado para considerar como uma possível detecção apenas quando o número de pixels brancos ultrapassava esse valor por pelo menos dois quadros consecutivos. Em seguida, o valor precisava cair abaixo de 1500 pixels para considerar que a garrafa havia completado sua passagem.



Fig. 4. Implementação final do sistema em ambiente fabril, com sobreposição da contagem e detecção de garrafas.

III. RESULTADOS E DISCUSSÕES

O sistema foi testado em uma linha de produção industrial de bebidas para validar seu desempenho na contagem em tempo real de garrafas tampadas. Foram conduzidos seis cenários de teste distintos, sendo três cenários referente à resposta de referência, onde foi realizado a técnica de *ground truth* [15] para se obter as métricas e os cenários restantes foram referente ao projeto em produção.

A. Resposta de Referência

Para avaliar a precisão do sistema proposto, foi utilizada a técnica de *ground truth*, que consiste na contagem manual de objetos em vídeos para posterior comparação com os resultados gerados automaticamente. Essa abordagem é amplamente adotada em tarefas de visão computacional para estabelecer uma base de referência confiável [15].

Três vídeos foram analisados quadro a quadro, com anotações feitas manualmente sobre a quantidade de garrafas

tampadas e destampadas. O objetivo era verificar se o sistema contava corretamente apenas as garrafas tampadas, conforme especificado em sua lógica de segmentação.

A Tabela I resume os dados de cada amostra, destacando os valores reais, os obtidos pelo sistema, e se houve discrepância na contagem.

TABLE I
RESULTADOS COMPARATIVOS ENTRE GROUND TRUTH E SISTEMA

Amostra	Duração (s)	Garrafas Tampadas		Erro
		Real	Sistema	
01	29	78	78	0
02	62	165	165	0
03	99	266	264	2

B. Análise dos Erros Observados

A discrepância de duas garrafas na Amostra 03 ocorreu devido à falha na detecção das tampas durante os segundos 26 e 48 da gravação. Nessas situações, as garrafas estavam parcialmente sobrepostas ou posicionadas em ângulos que reduziram a intensidade da cor esperada na ROI. Como consequência, o processo de segmentação em HSV e a limiarização não geraram uma quantidade suficiente de pixels brancos para ultrapassar o limiar mínimo estabelecido, impedindo a contabilização correta desses objetos.

Esses casos resultaram em falsos negativos. Ainda assim, considerando o total de 266 garrafas tampadas, o erro percentual foi inferior a 1%, o que demonstra a robustez da abordagem adotada, mesmo diante de pequenas variações no cenário de produção.

C. Métricas de Avaliação

As métricas de avaliação são amplamente utilizadas para avaliar o desempenho de sistemas de classificação e reconhecimento de padrões. Para isso, foi construída uma **matriz de confusão**, apresentada na Tabela II, com base na comparação entre as detecções realizadas pelo sistema e os valores reais observados em um conjunto de testes.

TABLE II
MATRIZ DE CONFUSÃO

		Detectada	
		Sim	Não
Real	Sim	VP = 506	FN = 2
	Não	FP = 0	VN = 6

A partir dessa matriz, é possível calcular métricas fundamentais para a análise de desempenho do sistema, como Precisão, Revocação e F1-score.

A **Precisão** indica a proporção de garrafas detectadas corretamente em relação ao total de detecções realizadas [11].

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (1)$$

A **Revocação** mede a capacidade do sistema de identificar todas as garrafas tampadas presentes na linha de produção [11].

$$\text{Revocação} = \frac{TP}{TP + FN} \quad (2)$$

Por fim, o **F1-score** representa a média harmônica entre Precisão e Revocação, oferecendo uma medida balanceada da eficácia do sistema [11].

$$\text{F1-score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (3)$$

Valores elevados dessas métricas são desejáveis e refletem um sistema com baixa taxa de falsos positivos e falsos negativos, essencial para aplicações industriais onde a confiabilidade na contagem impacta diretamente a eficiência operacional e o controle de qualidade.

D. Resultados Quantitativos

As métricas de Precisão, Revocação e F1-score foram calculadas com base nos valores extraídos da matriz de confusão apresentada na Tabela II.

TABLE III
MÉTRICAS DE DESEMPENHO CALCULADAS A PARTIR DA MATRIZ DE CONFUSÃO

Precisão (%)	Revocação (%)	F1-score (%)
100,0	99,6	99,8

Os resultados evidenciam a alta precisão do sistema, mesmo em um ambiente industrial real, com diferentes condições operacionais. A ausência de falsos positivos e o baixo número de falsos negativos demonstram que a estratégia baseada em segmentação HSV e contagem por ROI fixa é eficaz para a tarefa de contagem de garrafas tampadas.

O F1-score de 99,8% reforça a confiabilidade da solução proposta, tornando-a apropriada para aplicações industriais que exigem precisão e robustez na detecção em tempo real.

E. Testes em Ambiente Industrial

Para validar o desempenho da solução proposta em condições reais de operação, foram realizados três testes distintos em uma linha de produção de bebidas, com o objetivo de comparar diretamente os dados obtidos pelo sistema baseado em visão computacional com os valores registrados pelo Controlador Lógico Programável (CLP) [16] da máquina envasadora.

O sensor do CLP está instalado no interior da máquina envasadora, antes do processo de enchimento das garrafas, enquanto o sistema de visão computacional foi posicionado estrategicamente após a etapa de tampagem. Essa disposição resultou em uma defasagem física entre os dois pontos de contagem, o que é relevante para a análise, pois permite avaliar o impacto de eventuais perdas ou falhas entre as duas etapas, como quedas de garrafas, obstruções ou desvios na esteira.

A estratégia de validação foi conduzida principalmente durante paradas programadas e não programadas da linha de produção, momento em que não havia trânsito de garrafas entre os pontos de medição. Esse procedimento foi essencial

para garantir que os valores obtidos em ambas as contagens pudessem ser confrontados de forma direta e precisa, sem interferências dinâmicas, permitindo identificar com clareza a origem de eventuais discrepâncias.




Fig. 5. Localização dos sistemas de contagem: CLP antes do envase e Rock Pi S após a tampagem.

F. Resultados dos Testes em Ambiente Industrial

No **Teste 01**, observou-se uma discrepância inicial de até 12,4%, devido principalmente à queda de garrafas após a tampagem que não eram captadas pelo sistema. No entanto, mesmo com cinco ciclos de parada, o sistema manteve desempenho estável e consistente, com diferença final de apenas 2,3%.

TABLE IV
RESULTADOS DA VALIDAÇÃO – TESTE 01

Horário	CLP Mem.	CLP Real	Rock Pi S	Dif.	Dif. (%)
14:52	958	0	0	0	0.0
15:00	1368	410	359	51	12.4
15:04	1740	782	719	63	8.7
15:06	1967	1015	940	75	7.3
15:15	2731	1773	1696	77	4.3
15:41	4494	3536	3454	82	2.3

Após ajuste do posicionamento da câmera, o **Teste 02** apresentou resultados mais precisos, com diferenças inferiores a 1,2%, mesmo em condições de operação contínua e variação na presença de garrafas tampadas.

TABLE V
RESULTADOS DA VALIDAÇÃO – TESTE 02

Horário	CLP Mem.	CLP Real	Rock Pi S	Dif.	Dif. (%)
14:09	0	473	471	2	0.4
14:13	0	875	865	10	1.2

Por fim, o **Teste 03** realizado com configuração idêntica ao teste anterior, reforçou a confiabilidade do sistema: mesmo com mais de 11 mil garrafas contadas, a diferença percentual máxima observada foi de apenas 0,7%.

G. Aplicabilidade Industrial

O protótipo desenvolvido demonstrou um desempenho robusto em campo, mesmo diante das variações e desafios operacionais inerentes ao ambiente fabril. Durante os testes, os operadores puderam acompanhar em tempo real as contagens realizadas pelo sistema de visão computacional por meio da

TABLE VI
RESULTADOS DA VALIDAÇÃO – TESTE 03

Horário	CLP Mem.	CLP Real	Rock Pi S	Dif.	Dif. (%)
14:09	0	0	0	0	0.0
14:50	5155	5155	5118	37	0.7
15:23	9690	9690	9624	66	0.6
16:01	11899	11899	11813	86	0.7

interface gráfica, o que facilitou a comparação direta com o contador interno da máquina, baseado em sensores tradicionais conectados ao CLP. Essa visibilidade imediata permitiu maior controle e rastreabilidade da produção, além de fornecer uma ferramenta adicional de validação para a equipe de operação.

A baixa taxa de discrepância observada entre as contagens — especialmente nos testes finais, que apresentaram margens de erro inferiores a 1% — reforça a confiabilidade da solução proposta. Mesmo diante de situações como mudanças de turno, pequenas variações na posição das garrafas, ou alterações de ritmo na linha de produção, o sistema manteve precisão e estabilidade, validando a eficácia do modelo de segmentação por cor e da estratégia de contagem empregada.

IV. CONCLUSÃO

Este artigo apresentou o desenvolvimento e a validação de um sistema de baixo custo baseado em visão computacional para contagem em tempo real de garrafas tampadas em ambientes industriais de produção. A solução proposta, fundamentada em técnicas tradicionais de processamento de imagens, demonstrou elevada acurácia e robustez em diferentes cenários de teste, sem a necessidade de modelos de aprendizado profundo ou aceleração por GPU.

Os resultados experimentais confirmam a viabilidade da implantação deste sistema em linhas de produção reais, com F1-score superior a 99,7%. A utilização de uma ROI fixa e a segmentação baseada em HSV mostraram-se eficazes na extração de características relevantes, mantendo a eficiência computacional.

A simplicidade, replicabilidade e os baixos requisitos de hardware tornam esta solução uma alternativa viável para pequenas e médias indústrias que desejam melhorar o controle de qualidade e reduzir erros operacionais.

Como desenvolvimento futuro, propõe-se integrar modelos leves de redes neurais, a fim de aumentar a robustez da detecção em cenários mais complexos — por exemplo, na presença de sobreposição de objetos ou de variações abruptas de iluminação. Além disso, propõe-se integrar comunicação sem fio, registro em nuvem e um banco de dados para armazenamento em tempo real, expandindo o monitoramento remoto e possibilitando tanto análises instantâneas quanto históricas. Essa infraestrutura sustenta um módulo de supervisão remota que permite aos gestores acompanhar e ajustar a produção sempre que necessário, elevando a eficiência operacional e tornando o sistema uma ferramenta versátil e acessível para empresas de diferentes portes e segmentos. Dessa forma, gestores poderão acompanhar e ajustar a produção sempre

que necessário, elevando a eficiência operacional e tornando o sistema uma ferramenta versátil e acessível para empresas de diversos portes e segmentos.

Por fim, propõe-se implementar funcionalidades como a detecção de rótulos, a contagem de garrafas sem tampa e o monitoramento do nível de líquido, viabilizando uma avaliação ainda mais abrangente da qualidade do produto. Esses recursos permitirão identificar rótulos ausentes ou mal aplicados, além de detectar desvios no volume de enchimento.

AGRADECIMENTOS

Os autores gostariam de agradecer à Universidade do Estado do Amazonas (UEA), pelo suporte acadêmico e pelas oportunidades oferecidas durante o desenvolvimento deste trabalho.

Agradecimentos especiais ao Professor Manuel Cardoso e sua empresa, pelas orientações, contribuições técnicas e pela disponibilização do projeto.

REFERENCES

- [1] J. S. M. A. da Silva, “Como Análise Sensorial Contribui para o Controle de Qualidade na Indústria de Refrigerante”, *Mostra de Inovação e Tecnologia São Lucas*, vol. 4, no. 1, 2023.
- [2] F. A. Silva, “Técnicas de visão computacional para contagem de ovos de nematoides-das-galhas”, Trabalho de Conclusão de Curso, *Instituto Federal Goiano*, Morrinhos, 2024.
- [3] T. J. Sejnowski, “A Revolução do Aprendizado Profundo”, 1ª ed., São Paulo, SP: Alta Books, 2019.
- [4] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Las Vegas, NV, USA, 2016, pp. 779–788.
- [5] A. G. Howard *et al.*, “MobileNets: Efficient convolutional neural networks for mobile vision applications,” *arXiv preprint arXiv:1704.04861*, 2017.
- [6] P. Kumar, A. Singh, and J. Doe, “A survey on deep learning hardware accelerators for AI,” *ACM Comput. Surv.*, vol. 58, no. 3, pp. 1–35, 2025.
- [7] Logitech, “C920S Pro HD Webcam”, *Logitech*. [Online]. Disponível em: <https://www.logitech.com/pt-br/shop/p/c920s-pro-hd-webcam.960-001257>. [Acessado: 24-jul-2025].
- [8] Radxa, “ROCK Pi S Wiki”, *Radxa*. [Online]. Disponível em: <https://wiki.radxa.com/RockpiS>. [Acessado: 24-jul-2025].
- [9] A. O. Artero, *Inteligência artificial: Teórica e prática*. São Paulo: Editora Livraria da Física, 2009.
- [10] R. C. Gonzalez and R. E. Woods, *Processamento digital de imagens*, 3ª ed. São Paulo: Pearson Prentice Hall, 2009.
- [11] P. F. Matos *et al.*, “Relatório técnico: Métricas de avaliação,” Univ. Federal de São Carlos, 2009.
- [12] L. E. Borges, *Python para desenvolvedores: Aborda Python 3.3*. São Paulo: Novatec Editora, 2014.
- [13] R. Laganiere, *OpenCV computer vision application programming cookbook*, 2nd ed. Birmingham, U.K.: Packt Publishing, 2013.
- [14] I. Idris, *NumPy: Beginner's guide*, 3rd ed. Birmingham, U.K.: Packt Publishing, 2015.
- [15] S. Krig, “Ground truth and annotations,” in *Computer Vision Metrics: Survey, Taxonomy, and Analysis*. Cham, Switzerland: Springer, 2014, pp. 91–115.
- [16] H. C. D. Azevedo, “Controlador lógico programável aplicado à Indústria 4.0,” Dissertação de Mestrado, Programa de Pós-Graduação em Ciência, Tecnologia e Inovação, *Univ. Federal do Rio Grande do Norte*, Natal, 2018. [Online].
- [17] L. S. C. Ardila, “Sistema de caracterización morfológica de racimos de banana en la zona del Urabá Antioqueno mediante procesamiento digital de imágenes,” Trabalho de Graduação, *Escuela de Ingeniería de Antioquia (EIA)*, 2021. [Online].
- [18] M. Singh and S. Indu, “BGR to HSV based text extraction from manuscripts using slidebars,” in *Proc. Asian Conf. Innov. Technol.*, 2021, pp. 1–6.
- [19] M. E. Stivanello, “Inspeção industrial através de visão computacional,” *Univ. Regional de Blumenau*, 2004.
- [20] L. Barba-Guamán, J. Naranjo, and A. Ortiz, “Deep learning framework for vehicle and pedestrian detection in rural roads on an embedded GPU,” *Electronics*, vol. 9, no. 4, p. 589, 2020.
- [21] A. R. Backes and J. J. M. S. Junior, *Introdução à visão computacional usando MATLAB®*. Rio de Janeiro: Alta Books, 2016.
- [22] H. Pedrini and W. R. Schwartz, *Análise de imagens digitais: Princípios, algoritmos e aplicações*. São Paulo: Thomson Learning, 2008.
- [23] M. A. A. Pérez, “Espacios de color RGB, HSI y sus generalizaciones a n-dimensiones,” *INAOE*, Tonantzintla, México, 2009.
- [24] G. A. de Souza, “Inspeção automática da qualidade de codificação em garrafas PET utilizando visão computacional em sistema embarcado,” Trabalho de Conclusão de Curso, *Univ. Federal do Rio Grande do Sul*, 2021.
- [25] U. T. Machado, “Inspeção automática de frascos utilizando visão computacional em sistema embarcado,” Trabalho de Conclusão de Curso, *Univ. de Caxias do Sul (UCS)*, 2021.
- [26] R. C. Gonzalez, R. E. Woods, and S. L. Eddins, *Digital image processing using MATLAB*, 2nd ed. Knoxville, TN: Gatesmark Publishing, 2009.
- [27] C. Niu, Q. Zhu, Y. Wang, X. Zhou, and W. Shen, “Real-time counting system of glass bottle based on multi-objects tracking,” in *Proc. 2021 China Autom. Congr. (CAC)*, Beijing, China, Oct. 2021, pp. 5402–5407.
- [28] U. Kaewmorakot, L. Poolperm, S. Tansriwong, and P. Prongphimai, “The development of prototype of automated bottle caps visual inspection system,” in *Proc. 2022 Int. Electr. Eng. Congr. (iEECON)*, Khon Kaen, Thailand, Mar. 2022, pp. 1–4.