Revista ARACÊ
ISSN: 2358-2472

COMPARAÇÃO DE MÉTODOS DE EXTRAÇÃO DA REGIÃO DE INTERESSE PARA DETECÇÃO DE SUJEIRA EM PAINÉIS FOTOVOLTAICOS COM YOLO EM UM SISTEMA EMBARCADO

COMPARISON OF REGION OF INTEREST EXTRACTION METHODS FOR DIRT DETECTION IN PHOTOVOLTAIC PANELS WITH YOLO IN AN EMBEDDED SYSTEM

COMPARACIÓN DE MÉTODOS DE EXTRACCIÓN DE REGIONES DE INTERÉS PARA LA DETECCIÓN DE SUCIEDAD EN PANELES FOTOVOLTAICOS CON YOLO EN UN SISTEMA EMBEBIDO

https://doi.org/10.56238/arev8n11-080

Data de submissão: 16/10/2026 **Data de publicação:** 16/11/2026

Vinicius Amaral Ornelas
Graduando em Engenharia de Controle e Automação
Instituição: Instituto Federal de Educação, Ciência e Tecnologia de Rondônia (IFRO)
E-mail: v.ornelas@estudante.ifro.edu.br

Loyse Gomes Queiroga
Graduanda em Engenharia de Controle e Automação
Instituição: Instituto Federal de Educação, Ciência e Tecnologia de Rondônia (IFRO)
E-mail: loyse.queiroga@estudante.ifro.edu.br

Erickson Thiago Sales Lira
Graduando em Engenharia de Controle e Automação
Instituição: Instituto Federal de Educação, Ciência e Tecnologia de Rondônia (IFRO)
E-mail: erickson.l@estudante.ifro.edu.br

Kaio Burgel Freitas
Graduando em Engenharia de Controle e Automação
Instituição: Instituto Federal de Educação, Ciência e Tecnologia de Rondônia (IFRO)
E-mail: kaioburgem.com@gmail.com

Kariston Dias Alves
Doutorando em Engenharia Elétrica
Instituição: Instituto Federal de Educação, Ciência e Tecnologia de Rondônia (IFRO)
E-mail: kariston.alves@ifro.edu.br

RESUMO

A perda de eficiência em painéis fotovoltaicos pode ser causada pelo acúmulo de sujeira e limitações dos métodos convencionais de limpeza. Este trabalho surge da necessidade de soluções automatizadas e de baixo custo. Objetivou-se comparar três abordagens para a extração da região de interesse, segmentação por IA, detecção por bounding box e visão computacional, todas integradas a modelos YOLO de detecção de sujeira, visando sua aplicação em um sistema embarcado. Por isso, foram treinados dois conjuntos de dados, totalizando 1378 imagens, seguido da avaliação de métricas como

Revista ARACÊ
ISSN: 2358-2472

latência, taxa de acerto e precisão obtidas em um Raspberry PI 4. Desse modo, observou-se que os modelos de detecção por bounding box alcançaram os melhores resultados com taxa de detecção de sujeira de 99,71%, confiança média de 0,88 e tempo médio de 511 ms por imagem, cerca de 2 FPS. Já a segmentação por IA, embora mais precisa espacialmente, mostrou-se inviável para tempo real devido à alta latência com 1,74 s por imagem. O que permite concluir que o pipeline com detecção YOLO 11n ou YOLO v8n é o mais adequado para um robô de limpeza autônomo que se desloca sob painéis solares.

Palavras-chave: Visão Computacional. Painéis Fotovoltaicos. Sistema Embarcado. YOLO.

ABSTRACT

The loss of efficiency in photovoltaic panels can be caused by the accumulation of dirt and limitations of conventional cleaning methods. This work is justified by the need for automated and low-cost solutions. The objective was to compare three approaches for extracting the region of interest: AI segmentation, bounding box detection, and computer vision, all integrated with YOLO dirt detection models, aiming at their application in an embedded system. Therefore, two datasets were trained, totaling 1378 images, followed by the evaluation of metrics such as latency, hit rate, and accuracy obtained on a Raspberry Pi 4. Thus, it was observed that the bounding box detection models achieved the best results with a dirt detection rate of 99.71%, an average confidence of 0.88, and an average time of 511 ms per image, approximately 2 FPS. AI segmentation, although more spatially precise, proved unfeasible for real-time due to high latency of 1.74 s per image. This leads to the conclusion that the YOLO 11n or YOLO v8n detection pipeline is the most suitable for an autonomous cleaning robot that moves under solar panels.

Keywords: Computer Vision. Solar Panels. Embedded System. YOLO.

RESUMEN

La pérdida de eficiencia en paneles fotovoltaicos puede ser causada por la acumulación de suciedad y las limitaciones de los métodos convencionales de limpieza. Este trabajo surge de la necesidad de soluciones automatizadas y de bajo costo. Se objetivó comparar tres enfoques para la extracción de la región de interés, segmentación por IA, detección por bounding box y visión computacional, todas integradas a modelos YOLO de detección de suciedad, con el propósito de su aplicación en un sistema embarcado. Por ello, se entrenaron dos conjuntos de datos, totalizando 1378 imágenes, seguido de la evaluación de métricas como latencia, tasa de acierto y precisión obtenidas en una Raspberry PI 4. De este modo, se observó que los modelos de detección por bounding box alcanzaron los mejores resultados con tasa de detección de suciedad del 99,71%, confianza promedio de 0,88 y tiempo promedio de 511 ms por imagen, aproximadamente 2 FPS. Por su parte, la segmentación por IA, aunque más precisa espacialmente, se mostró inviable para tiempo real debido a la alta latencia con 1,74 s por imagen. Lo que permite concluir que el pipeline con detección YOLO 11n o YOLO v8n es el más adecuado para un robot de limpieza autónomo que se desplaza bajo paneles solares.

Palabras clave: Visión Computacional. Paneles Fotovoltaicos. Sistema Embarcado. YOLO.

Revista ARACÊ
ISSN: 2358-2472

1 INTRODUÇÃO

O crescimento na busca por fontes eficientes e renováveis para a geração de energia tem levado ao aumento na utilização da energia fotovoltaica. No contexto mundial, o setor de energia solar é liderado em capacidade energética por China e Estados Unidos atualmente, com 886,12 GW e 176,114 GW de potência respectivamente, segundo dados da Agência Internacional para as Energias Renováveis (IRENA, 2025). No Brasil, o cenário observado é de fortalecimento recente, em que medidas realizadas a partir da década de 2010, como a regulamentação do uso de sistemas fotovoltaicos por meio da Resolução Normativa 482 da ANEEL e leilões de energia contribuíram para a expansão da geração de energia solar (ARAÚJO; DUARTE, 2025).

Atualmente, a energia solar é o quarto maior sistema de energia utilizado no Brasil, representando 8,0% da capacidade instalada da matriz elétrica do país, estando também incluída nos 19,5% correspondentes à Micro e Minigeração Distribuída (MMGD), que se encontram em segundo lugar, atrás somente da energia hidrelétrica, conforme ONS (2026). Além disso, a geração de energia fotovoltaica no país alcançou uma potência operacional de 64 GW, com perspectivas de aumento de mais 10,6 GW para o ano de 2026, evidenciando a crescente da matriz energética solar no país (ABSOLAR, 2026).

Com a expansão na instalação desses sistemas, certas demandas tornam-se relevantes, como a eficiência na geração de energia, que é considerada um elemento fundamental. Para que haja a garantia de êxito em relação a esse fator, é necessário que a instalação de painéis fotovoltaicos ocorra em ambientes externos e abertos com alta incidência solar, o que resulta na sua exposição à sujeira e partículas, comprometendo a geração de energia elétrica por conta da redução de energia solar recebida, uma vez que os raios incidentes acabam dispersos pela sujeira (ILSE *et al.*, 2018).

Desse modo, torna-se importante a análise do impacto da presença de partículas e poeira nos módulos, para que haja o controle do nível de sujidade e rotinas para sua limpeza possam ser estabelecidas de maneira a potencializar as etapas que a envolvem a geração e propiciar a economia de recursos. A limpeza de painéis fotovoltaicos é comumente realizada das seguintes maneiras: natural, que tem o processo baseado na remoção dos resíduos pela chuva ou pelo vento, e a manual, que é realizada por seres humanos utilizando-se de acessórios como esfregões, vassouras ou máquinas para a execução da limpeza, conforme Pinto (2019).

Entretanto, a execução do processo manual pode representar riscos a quem o realiza, especialmente se os módulos estiverem instalados em locais altos, além do baixo custo-benefício que o método apresenta, uma vez que, de acordo com Al-Zaben e Al-Manaseer (2025) o método pode levar a resultados insuficientes pela inconsistência da ação e observação humana, em que a limpeza pode

Revista ARACÊ
ISSN: 2358-2472

ser realizada de maneira incorreta. A incerteza de resultados eficazes estimula a busca por novos mecanismos para realização da limpeza desses sistemas, favorecendo soluções automatizadas em sua variedade de técnicas e processos.

Desta forma, métodos baseados em visão computacional, pela característica que apresentam de simular a visão do ser humano e sua capacidade de reconhecer e compreender o que enxerga e captar informações, conforme afirmam Gao *et al.* (2020), bem como o *You Only Look Once* (YOLO), que, segundo Redmon *et al.* (2016), é um modelo de detecção com um desempenho mais veloz do que outros modelos de redes neurais por trabalhar no reconhecimento de objetos com regressão única, se destacam como ferramentas que podem ser empregadas na inspeção de falhas e sujeiras em sistemas fotovoltaicos aplicada em um modelo voltado para a reconhecimento dos painéis fotovoltaicos e que possua a capacidade de classificar o grau de sujidade, avaliando a necessidade de limpeza, seja esta suave ou profunda, o que fornece um diferencial para a preservação do potencial de geração de energia dos módulos.

Assim, este trabalho apresenta uma solução baseada em aprendizado de máquina para, primeiramente, detectar ou segmentar os painéis fotovoltaicos e realizar a identificação das áreas em que haja a presença de sujeira, utilizando diferentes versões do modelo YOLO (v8, v11 e v26) para a elaboração de um protótipo que possua a capacidade de realizar a classificação, de modo a ser utilizada para o reconhecimento, da magnitude e da presença de sujeira em painéis fotovoltaicos, otimizando os processos de manutenção e limpeza que ocorrem, bem como seu desempenho em um sistema embarcado real.

2 REFERENCIAL TEÓRICO

A observação dos painéis fotovoltaicos para identificação da presença de sujeira se mostra importante, considerando-se o fato de que os níveis de sujeira determinam a necessidade da realização de limpeza para preservação do funcionamento adequado dos sistemas fotovoltaicos na geração de energia. Além dos riscos presentes para indivíduos ao realizar as atividades relacionadas à limpeza manual, em casos em que a técnica de limpeza natural é a estratégia adotada, as perdas de eficiência devido ao acúmulo de poeira e partículas podem chegar a 20% durante o período do verão, em que há a ausência das chuvas, como apontam os autores Zorrilla-Casanova *et al.* (2011).

Além disso, a inclinação dos painéis afeta a eficácia do processo, visto que a gravidade e os agentes de limpeza como a chuva apresentam resultados melhores na remoção da sujeira quando a inclinação dos painéis na instalação é realizada com ângulos maiores, e baixas inclinações (como

Revista ARACÊ
ISSN: 2358-2472

ângulos de 0 a 5º) apresentam maior facilidade para o acúmulo desses resíduos e tendem a possuir perdas maiores de eficiência, conforme Misquita e Zilles (2022).

Buscando sanar as problemáticas existentes nesses métodos, novas tecnologias e soluções têm sido propostas e desenvolvidas visando otimizar esses processos e fornecer suporte para a realização de manutenções de maneira mais eficiente, como Santos (2023) que propôs um modelo de reconhecimento de sujidade de placas solares utilizando algoritmos de aprendizado de máquina *Light Gradient Boosting Machine* (LGBM) e *Extra Trees Classifier* (ETC), processando os dados com a ferramenta *PyCaret* e obtendo bons resultados de precisão (valores superiores a 90%), apresentando, no entanto, diferente objetivo de aplicação dos dados coletados (desenvolvimento de aplicativo móvel) e métodos de classificação, definindo apenas a presença de sujeira e sombreamento, sem quantificá-la.

Naeem *et al*. (2025), utiliza o aprendizado de máquina para a realização de reconhecimento dos painéis com um modelo baseado no YOLO, que obteve precisão de 0,854 nos resultados dos testes, embora houvesse limitações quanto aos tipos de detecção (restrito a identificação da presença de poeira ou excrementos de pássaros) e do conjunto de dados, em que a análise de desempenho foi limitada pela baixa quantidade de imagens disponíveis.

Di Tommaso *et al.* (2022) por sua vez, utilizaram YOLO para o reconhecimento de bordas das placas e a identificação da presença de defeitos, cujos resultados indicaram que o modelo utilizado realiza a detecção dos painéis com excelência e o reconhecimento de bordas e danos apresenta boa precisão (cerca de 98%), mas foram encontradas dificuldades na diferenciação dos níveis de sujeira, e a capacidade de integração do modelo com sistemas embarcados é desconhecida, uma vez que não foram realizados testes com tal finalidade, no que os autores afirmam que mais pesquisas eram necessárias. Há uma ampla gama de softwares e abordagens que podem ser testadas e aplicadas para o reconhecimento de padrões e objetos que serão classificados e utilizados em determinadas atividades.

Em contraste com as soluções propostas mencionadas, o trabalho proposto reúne capacidades da visão computacional com o uso do YOLO para atividades sequenciais. Em primeiro plano, realizando um reconhecimento de painéis fotovoltaicos para a identificação de sua área e bordas, e depois a identificação da presença de sujeira e quantificação conforme seu nível. Nesse sentido, serão analisados os resultados obtidos dos testes no sistema embarcado que foram coletados em testes com métodos de detecção e segmentação.

Revista ARACÊ
ISSN: 2358-2472

3 METODOLOGIA

3.1 CONJUNTO DOS DADOS

3.1.1 Dataset autoral

O primeiro *dataset* foi composto por 340 imagens de painéis solares capturadas simulando condições reais de operação, isto é, as fotos foram tiradas em diferentes ângulos, horários diferentes e em plantas de geração de energia fotovoltaica diferentes. O painel solar foi selecionado manualmente em cada imagem e foi rotulado usando segmentações em polígonos para o contorno. Em seguida, uma etiqueta (*tag*) "*solar_panel*" é colocada, para o painel e para o fundo da imagem foi classificado como *null*. O *dataset* foi dividido em treino (70%), validação (15%) e teste (15%).

3.1.2 Dataset público

Para ampliar a diversidade de dados de treino do modelo, um segundo *dataset* foi utilizado como uma fonte adicional de dados de imagens de painéis solares sujos, um *dataset* disponível publicamente no Roboflow Universe sob licença CC BY 4.0: *"solar panel dirt det"* (ALEX, 2024). Esse *dataset* contém 1038 fotos com as tags "*clean*" (limpo), "*high-dirty*" (muito sujo), e "*low-dirty*" (pouco sujo) e foi dividido em subconjuntos: teste, validação e treino, nas mesmas proporções do outro *dataset*. Anotações foram revisadas, foto por foto, e, quando necessário, corrigidas para manter o padrão de qualidade e consistência.

Além disso, após a conferência das anotações, as imagens foram enviadas para o treinamento do modelo. Para o primeiro *dataset*, como a coleta foi realizada em dias diferentes, fez-se necessária uma análise das novas imagens geradas, e então, a adição e catalogação das fotos até o sistema conseguir localizar o painel solar.

3.1.3 Parâmetros utilizados

A tabela 1 resume os principais hiperparâmetros e as transformações de *data augmentation* utilizadas no treinamento. O framework Ultralyrics YOLO foi usado em todo o processo e para todos os modelos.

Revista ARACÊ
ISSN: 2358-2472

Tabela 1. hiperparâmetros do treinamento

Parâmetro	Valor
Resolução das imagens	320x320p
Batch size	16
Otimizador	AdamW
Taxa de aprendizado inicial (Ir0)	0,001
Taxa de aprendizado final (lrf)	0,0001
Momentum	0,9
Weight decay	0,0005
warm up epochs	3
Rotação em graus(degrees)	+-10º
translação	0,1
Escala	0,5
Shear	+-2º
Flip horizontal	0,5
Flip vertical	0,2
Mosaic	0,5
Early stopping	20 épocas sem melhoria

Fonte: Elaborada pelos próprios autores.

3.2 TREINAMENTO DOS MODELOS

O fluxo de trabalho (*pipeline)* proposto para o sistema pode ser dividido em duas etapas sequenciais. Desse modo, foram utilizados os modelos YOLOv8n, YOLO11n e YOLO26n, com o objetivo de identificar o painel fotovoltaico e, em seguida, identificar e quantificar, em pouca ou muita, a sujeira em sua superfície:

1. Segmentação e extração da região de interesse.

Nessa etapa, o modelo analisa a imagem completa capturada pela câmera para localizar e delimitar o painel fotovoltaico. A partir da estimativa de localização gerada, é realizado o corte da região ocupada pelo painel para separá-lo dos demais objetos e ambiente.

2. Detecção e classificação de sujeira.

Em sequência, outro modelo YOLO, treinado especificamente para essa função, analisa apenas a região do painel extraída procurando pela presença de sujeira.Essa estratégia reduz a influência de outros elementos e diminui a ocorrência de falsas detecções.

Todos os modelos começaram com os pesos no conjunto de dados YOLO v8 *Oriented Bounding Boxes* e foram submetidos ao ajuste fino com os conjuntos de dados descritos no item 3.1. Para o treinamento, os parâmetros da Tabela 1 foram seguidos. Na sequência os modelos foram salvos no formato nativo *PyTorch* (.pt) e convertidos para ONNX para quantização no formato INT8.

Revista ARACÊ
ISSN: 2358-2472

3.3 MODELOS DE EXTRAÇÃO DA ÁREA DE INTERESSE OU ROI

Para encontrar a área, foram utilizados 3 diferentes métodos: por inteligência artificial, por detecção por *bounding box* e por visão computacional.

3.3.1 Método por segmentação por inteligência artificial

Nesse método, foi utilizado as variantes de segmentação de instâncias (que são identificados com o sufixo "-seg" juntamente às versões dos modelos): YOLO v8n-seg, YOLO 11n-seg e YOLO 26-seg. Esses modelos geram máscaras binárias pixel por pixel que contornam exatamente os limites dos painéis, mas acabam tendo um custo computacional mais elevado.

3.3.2 Método por detecção por bounding box

Utilizando a mesma arquitetura, mas agora na versão de detecção de objetos, YOLO v8n, YOLO 11n, YOLO 26n. Esses são capazes de criar várias caixas retangulares que sobrepõem o painel e extraem o painel escolhendo a caixa de maior confiança.

3.3.3 Método por visão computacional

Para se ter uma base de comparação, foi montado um algoritmo sem nenhum aprendizado de máquinas, baseado na limiarização do espaço em cores HSV e operações morfológicas. As operações começam com a conversão da imagem RGB para HSV. Na sequência aplica-se um filtro passa-faixa nos canais H(90-130), S (50-255) e V(50-255) que representam a cor azul escura, típica de placas fotovoltaicas. Então realizou-se o fechamento morfológico, com um kernel 15x15, para preencher os buracos, e, a abertura morfológica, kernel 5x5, para reduzir os ruídos. Desta forma, foi selecionado o maior contorno encontrado e foi gerada uma máscara binária e o painel foi recortado usando *bounding box* do contorno.

Os valores de HSV foram calibrados manualmente com base no conjunto de fotos de imagem do dataset de treino, ou seja, qualquer variação na iluminação, reflexo das placas ou câmera, resultará na alteração dos resultados e será necessário realizar outra calibração manual se o modelo for utilizado em uma planta diferente.

3.4 AVALIAÇÃO DOS MODELOS

O processo de comparação entre os três extratores (segmentação, detecção e visão clássica) com os três modelos de detecção (YOLO v8n, YOLO v11n, YOLO v26n) foi automatizado e seguiu os seguintes passos.

Revista ARACÊ
ISSN: 2358-2472

O pré-carregamento de todos os modelos em cache foi realizado para evitar viés de tempo na primeira inferência. Para cada uma das 207 imagens no diretório de validação, a imagem foi reduzida para 320x320 pixels. Em sequência, utilizou-se uma função específica para cada método. O tempo de extração então foi registrado, seguido da área da máscara/confiança, e então a ROI foi avaliada, e além de registrar o tempo de detecção, número de detecções, confianças mínimas e máximas e média, uma comparação com o *ground truth* foi realizada; Ressalta-se que, as imagens que ficaram com uma resolução menor que 50x50 pixels foram descartadas.

Na sequência, para todas as imagens do conjunto de validação, há as anotações manuais da sujeira (*ground truth)*, utilizadas para, a partir da comparação entre o conjunto de validação e as caixas delimitadoras, realizar o cálculo da *Intersection over Union* (IoU). A partir dessa base de comparação, foram obtidas as métricas de precisão (*Precision*), e revocação (*Recall*), nas quais os resultados variam de 0 a 1 (valores que representam 0% a 100%) e valores mais elevados indicam melhor desempenho. A precisão é um indicador que apresenta a medida da taxa de acertos do modelo ao realizar as predições, referindo-se portanto, à confiabilidade em relação à falsos-positivos, enquanto a revocação é um indicador utilizado para a medição da capacidade do modelo de realizar a detecção das instâncias de objetos (neste caso, de sujeira) nas imagens, analisando, dessa maneira, a confiabilidade do modelo em relação à falsos negativos. Os indicadores utilizados embasam o cálculo de duas das principais métricas de avaliação deste trabalho: o mAP@50 e o mAP@50-95 (*Mean Average Precision*).

O mAP@50 somente considera uma detecção correta quando a sobreposição entre a previsão do modelo e a anotação manual apresenta um IoU igual ou superior a 0,5 (50%). Essa métrica permite avaliar a capacidade do modelo de localizar os objetos de interesse. Já o mAP@50-95 calcula a média do mAP para diferentes limiares de IoU, variando de 0,50 a 0,95, em intervalos de 0,05. Ambas as métricas possuem uma variação de 0 a 1 (0% a 100%) assim como as que fundamentaram seus cálculos, de modo que valores mais próximos de 1 para as métricas calculadas representam maior eficácia, indicando que o modelo consegue não apenas identificar os objetos, mas também delimitar suas regiões com maior precisão espacial (PADILLA; NETTO; DA SILVA, 2020).

3.4.1 Critérios de seleção do melhor modelo

A escolha do modelo mais adequado para a aplicação deve levar em consideração a eficiência computacional, a capacidade de execução em um sistema embarcado com recursos limitados e a precisão de cada modelo. Para isso, foram considerados dois critérios principais: Apresentar bons resultados de detecção, ou seja, ter valores elevados de mAP@50 e *Precision*, além de apresentar baixa

Revista ARACÊ
ISSN: 2358-2472

latência de inferência. Para se ter uma referência, estabeleceu-se uma taxa de processamento de aproximadamente 2 a 3 quadros por segundo (FPS) no hardware utilizado.

3.5 OTIMIZAÇÃO PARA O SISTEMA EMBARCADO E BENCHMARKING

No processamento de algoritmos de visão computacional, como o YOLO, a inferência é geralmente realizada em supercomputadores ou servidores de alto desempenho com Unidades de Processamento Gráfico (GPUs) dedicadas. Todavia, a proposta está na utilização do modelo de visão computacional diretamente em um sistema embarcado que controla um robô de limpeza autônomo, ou seja, em um cenário sensível à utilização de equipamentos de peso elevado, custo e consumo energético.

Desta forma, um computador de alto desempenho foi utilizado apenas na fase de treino dos modelos, estando equipado com uma placa gráfica NVIDIA GeForce GTX 1660 SUPER, e um sistema embarcado foi utilizado na fase de inferência e aplicação prática. Em contraste, para a operação e avaliação do pipeline foi reproduzido em um Raspberry Pi 4 Model B (ARM Cortex-A72, 4 GB de RAM). Essa abordagem permite avaliar o comportamento dos modelos num ambiente mais próximo das condições reais de funcionamento do robô.

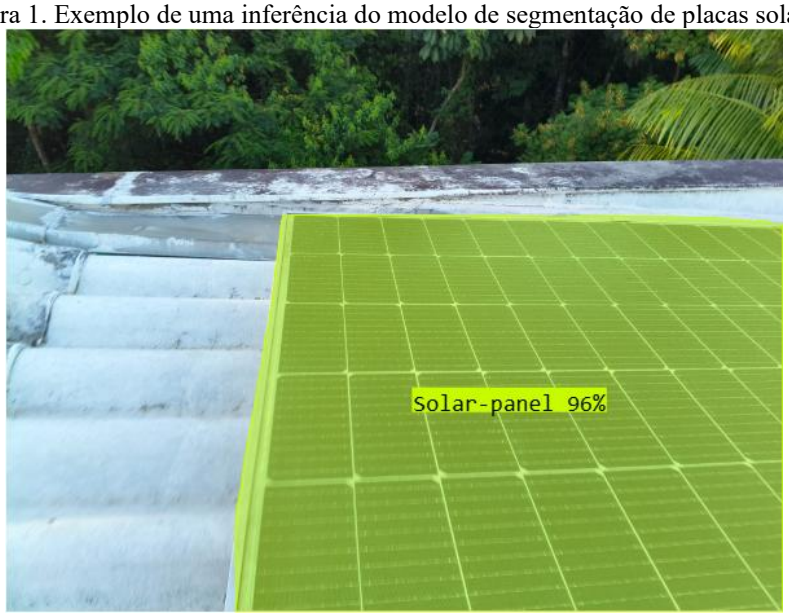
A utilização deste dispositivo que possui recursos computacionais limitados representa um dos principais desafios deste trabalho, na medida que se faz necessário fazer adaptações para garantir um desempenho adequado sem comprometer a capacidade de processamento do sistema. Por esse motivo, foi realizada a quantização dos modelos, processo que reduz o custo computacional e latência a um custo de perda de precisão.

A quantização dos modelos foi realizada pela biblioteca *onnxruntime.quantization* utilizando função *weight_type=Quant Type.Int8*. Foram realizados testes para todos os padrões de ONNX e int8 apresentou os resultados mais equilibrados em precisão, tamanho e latência. Para os testes, uma resolução de 640x640 pixels foi adotada.

Além disso, para reduzir os efeitos de inicialização do sistema, foram realizadas 5 inferências para o aquecimento antes das medições e cada modelo foi avaliado em 30 execuções, registrando as métricas de FPS, latência média e latência máxima (REDDI *et al.*, 2019).

Revista ARACÊ
ISSN: 2358-2472

Figura 1. Exemplo de uma inferência do modelo de segmentação de placas solares.



Fonte: Elaborada pelos próprios autores.

Figura 2. Exemplo de uma inferência do modelo de bounding box de sujeira.



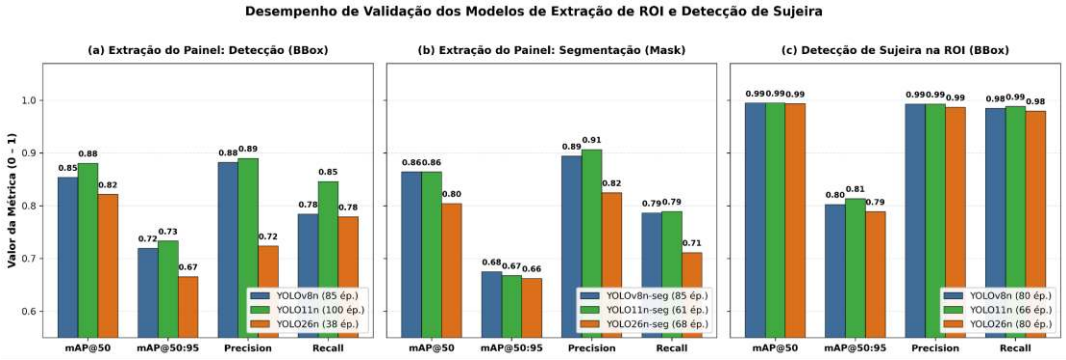
Fonte: Elaborada pelos próprios autores.

4 RESULTADOS E DISCUSSÕES

4.1 DESEMPENHO DOS MODELOS DE EXTRAÇÃO

Revista ARACÊ
ISSN: 2358-2472

Figura 3. Desempenho de validação dos modelos de extração de ROI e detecção de sujeira.



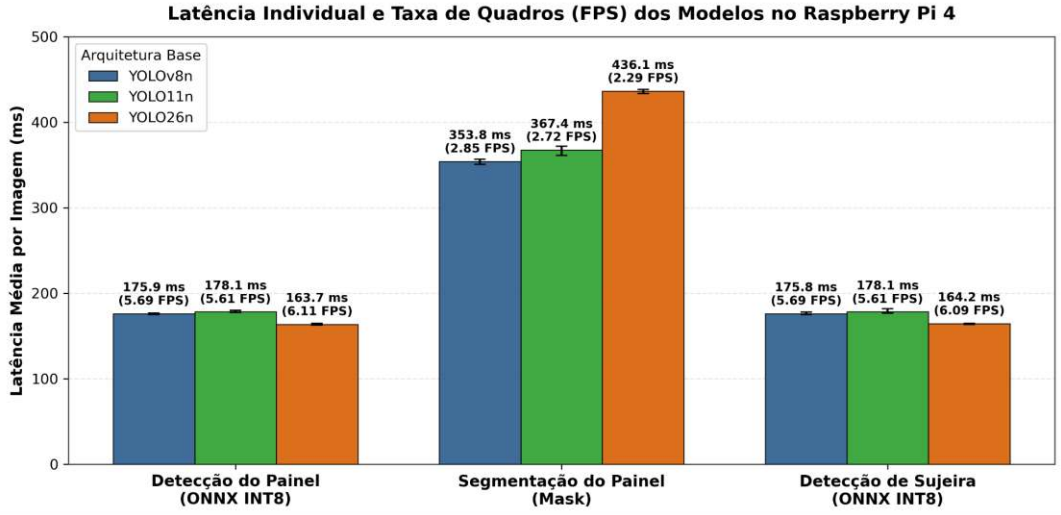
Fonte: Elaborada pelos próprios autores.

A Figura 3 apresenta o desempenho do processo de validação dos modelos de extração da região de interesse e detecção de sujeira, exibindo as métricas obtidas de acordo com as épocas de treinamento (apresentadas nos gráficos como "ép."), isto é, da quantidade de ciclos percorridos pelo modelo para realizar o processamento de todos os dados do *dataset*. Ao observar os segmentos 3(a) e 3(b) da figura, percebemos que os modelos de segmentação tiveram uma *Precision* consistentemente mais alta do que os de detecção. Em média, os modelos -"seg" alcançaram uma média de 4,3% maior do que sua variação de detecção. Isso confirma que as máscaras binárias de segmentação conseguem delimitar o contorno do painel com mais precisão e assim reduzir os falsos positivos. Por outro lado, o *Recall* médio de detecção com 0,803 supera o de segmentação de 0,762. Esse comportamento sugere que a detecção por bounding box é mais sensível para encontrar painéis solares em diferentes condições de aquisição das imagens com ângulos diferentes, sombras parciais e reflexos, enquanto segmentação por máscara prioriza a precisão espacial das bordas detectadas.

4.2 LATÊNCIA DOS MODELOS INDIVIDUAIS

Revista ARACÊ
ISSN: 2358-2472

Figura 4. Latência individual e taxa de quadros dos modelos no Raspberry Pi 4.



Fonte: Elaborada pelos próprios autores.

Em primeiro plano, podemos observar pela Figura 4 que, dentre os modelos de detecção do painel, o YOLOv26n se saiu melhor em termos de velocidade de inferência, alcançando 6,11 FPS estimados e uma latência média de 163,68. Logo na sequência vieram o YOLOv8n, 5,69 FPS e 175,88 ms, e o YOLOv11n com 5,61 FPS e 178,12 ms. Na prática, a diferença de latência entre eles é de aproximadamente 15 ms, então todos se mostraram perfeitamente viáveis para essa tarefa no hardware que foi utilizado.

Na sequência, dos modelos de segmentação, o mais rápido foi o YOLOv8n-seg, com 2,85 FPS estimados e latência de 353,79ms, seguido pelo YOLO 11-seg, 2,72 FPS e 367,37 ms e pelo YOLOv26-seg com 2,29 FPS e 436,15 ms. Comparando YOLOv8n de detecção com a sua variante de segmentação, percebe-se uma queda de praticamente 100% na velocidade e latência, o que reforça o que foi dito no item 3.3.1.

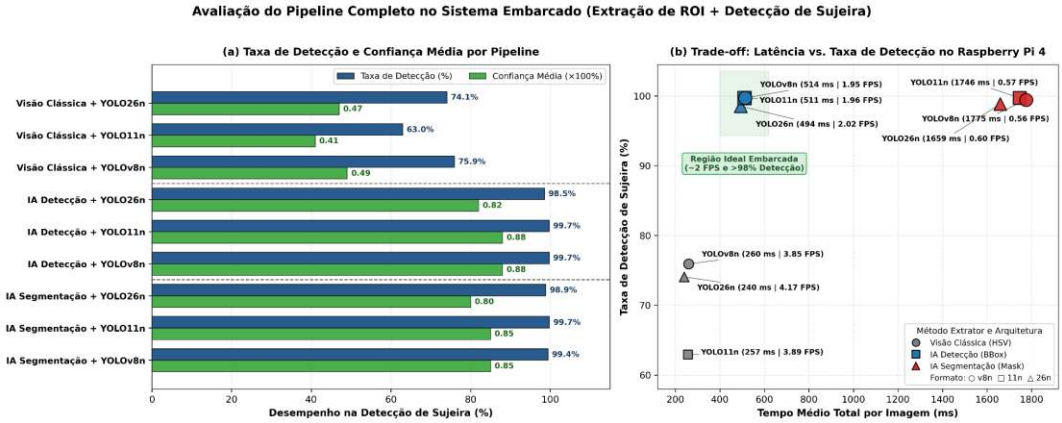
Para os modelos de detecção de sujeira, as latências foram praticamente iguais aos modelos de detecção do painel, o que já era esperado, visto que ambos compartilham a mesma arquitetura de base. Vale ressaltar, que esses foram os resultados individuais de cada modelo, no próximo teste o desempenho conjunto deles será avaliado.

4.3 AVALIAÇÃO DO PIPELINE COMPLETO NO SISTEMA EMBARCADO (INT8)

Na sequência, a avaliação do pipeline junta a extração da região de interesse, placa solar, com a detecção de sujeira, e isso nos permite ter uma visão completa de como o sistema se comporta no *Raspberry Pi*. Por isso foram processadas 207 imagens de validação, totalizando 2688 combinações A Tabela 8 apresenta as médias dos tempos e métricas de detecção de sujeira agrupadas por tipo de extrator.

Revista ARACÊ
ISSN: 2358-2472

Figura 5. Avaliação do pipeline completo no sistema embarcado.



Fonte: Elaborada pelos próprios autores.

Começando pela abordagem de visão computacional clássica, ela teve os menores tempos totais de processamento, entre 259 e 239 ms, e teve as piores taxas de detecção que estavam na faixa de 62,96% a 75,93%, e a confiança média variou de 0,41 a 0,49. Esse resultado pode ser entendido pelos comentários do item 3.3.3, pois essa abordagem é extremamente sensível a variações de luz, posição e até a reflexibilidade da placa analisada. Desse modo, trata-se de um método rápido, mas que só é viável em ambientes controlados e com a devida calibração de seus parâmetros.

Seguindo para os modelos de detecção por *bounding box*, foram os modelos com o maior equilíbrio em velocidade e precisão. Dessa forma, as combinações com YOLOv11n e YOLOv8n chegaram a taxas de detecção de 99,71% e confiança média de 0,88, e, em todos os testes o tempo médio ficou abaixo dos 515 ms, ou 2 fps estimados. Isso demonstra uma melhora significativa em relação ao método clássico analisado, e ainda se mantém computacionalmente viável em um sistema embarcado.

Por conseguinte, a abordagem de segmentação trouxe os maiores tempos do *pipeline*, variando entre 1,659 até 1,775 segundos por imagem. Desta forma, é perceptível a queda de 3,4 vezes da velocidade em relação à detecção por *bound box*. As taxas de detecção permaneceram na mesma faixa, e por isso não houve um ganho que justificasse o custo significativo de latência adicional, tendo em vista o cenário do sistema embarcado. O que na prática indica que, no resultado final, a precisão extra das máscaras de segmentação não se traduziu em benefício significativo na taxa de detecção.

Em síntese, quando olhamos o conjunto inteiro, a combinação que mais se destacou para uma implantação em um sistema embarcado num cenário real foi a combinação de detecção com YOLOv11n ou YOLOv8n. Porque apresentou uma taxa de detecção de 99,71%, confiança média de 0,88 e tempo total por volta de 511 ms e quase 2 FPS, o que pode ser adequado para um robô que anda

Revista ARACÊ
ISSN: 2358-2472

progressivamente sob um painel. Desse modo, se a prioridade for ter uma latência baixa e for aceitável uma leve queda na confiança, a melhor combinação encontrada foi o extrator YOLOv11n com o detector YOLOv11n, que atingiu 99,71% de taxa de detecção e 511 ms de tempo médio.

5 CONCLUSÃO

Esse estudo comparou 3 métodos de extração da região de interesse, segmentação por IA, detecção por *bounding box* e visão clássica por threshold HSV, todos integrados a um modelo de detecção de sujeira para sua aplicação em um sistema embarcado de baixo custo, Raspberry Pi 4. Os resultados mostraram que a segmentação entregou a maior precisão espacial com o YOLOv8seg chegando a um mAP@50 de 0,8641 para as máscaras e *Precision* de 0,9065, confirmando que as máscaras binárias conseguiram delimitar os contornos dos painéis com exatidão. Entretanto, essa vantagem veio com custo de latência alta, o tempo total médio foi de 1,74 segundos por imagem, o que resulta em apenas 0,58 FPS. Isso inviabiliza o uso desse método de extração em aplicações práticas em tempo real no hardware utilizado.

Além disso, os modelos de detecção por *bounding box* ofereceram o melhor equilíbrio entre velocidade e precisão. O YOLO 11n alcançou mAP@50 de 0,8806 na detecção do painel, com tempo total médio de 511 ms e taxa de detecção de sujeira de 99,71% quando combinado com o detector YOLO 11n. A diferença de desempenho entre os três modelos de detecção de sujeira foi mínima com mAP@50 entre 0,9933 e 0,9947. Por isso todos os modelos se mostraram adequados para uso em tempo real em um sistema embarcado, uma vez que as diferenças de mAP@50 foram mínimas. Para a escolha pode ficar por conta da latência que se quer atingir.

Já a abordagem clássica de visão computacional, apesar de ter sido a mais rápida com um tempo médio de 252 ms, teve taxas de detecção mais baixas, máximo de 75,93%. Isso ocorre porque a abordagem baseada em segmentação por espaço de cores (HSV) depende da calibração manual e de um ambiente controlado. Para futuras melhorias irão ser testados outros métodos clássicos e combinações de técnicas, bem como detecção de bordas de Canny com a transformada Hough para as linhas retas, com o intuito de melhorar a robustez de extração da ROI.

Em síntese, a partir dos resultados apresentados, é recomendado para um robô de limpeza autônomo que se deslocará progressivamente sob painéis solares, adotar o *pipeline* com o extrator de ROI por detecção YOLO 11n ou YOLO v8n, combinado ao detector de sujeira YOLO 11n. Essa configuração entrega taxa de detecção de 99,71%, confiança média de 0,88 e tempo total por volta de 511 ms por imagem. Para trabalhos futuros, pretende-se implementar esse *pipeline* no ROS2 e validar em campo com o robô protótipo.

Revista ARACÊ
ISSN: 2358-2472

REFERÊNCIAS

ABSOLAR. Energia solar avança no Brasil e adiciona 10,6 GW em 2025, com mais de R$ 32,9 bi em investimentos. Publicado em: 23 fev. 2026. Disponível em:https://www.absolar.org.br/home/energia-solar-avanca-no-brasil-e-adiciona-106-gw-em-2025-com-mais-de-r-329-bi-em-investimentos/. Acesso em: 21 mai. 2026.

AL-ZABEN, H.; AL-MANASEER, Z. An overview of dust cleaning methods for solar photovoltaic systems: Jordan case study. MATEC Web of Conferences. v. 411, 2025. DOI:10.1051/matecconf/202541101007.

ALEX. Solar Panel Dirt Det Dataset. Roboflow Universe, 2024. Disponível em: https://universe.roboflow.com/alex-jcvyb/solar-panel-dirt-det. Acesso em: 14 jun. 2026.

DI TOMMASO, A.; BETTI, A.; FONTANELLI, G.; BENEDETTO,M. A Multi-Stage model based on YOLOv3 for defect detection PV panels based on IR and Visible Imaging by Unmanned Aerial Vehicle. Renewable Energy, v. 193, p. 941-962, 2022. DOI: https://doi.org/10.48550/arXiv.2111.11709.

DUARTE, C. H. C.; ARAÚJO, B. P. de. Geração de energia solar fotovoltaica no Brasil e o desenvolvimento da cadeia local de fornecedores. BNDES Setorial, Rio de Janeiro, v. 31, n. 59, p. 57-118, mar. 2025.

GAO, K; GANG, M.; PICIALLI, F.; CUOMO, S.; TU, J.; HUO, Z. Julia language in machine learning: Algorithms, applications, and open issues. Computer Science Review, v. 37, 2020. DOI: 10.1016/j.cosrev.2020.100254.

ILSE, K. K.; FIGGIS, B. W.; NAUMANN, V.; HAGENDORF, C.; BAGDAHN, J. Fundamentals of soiling processes on photovoltaic modules. Renewable and Sustainable Energy Reviews, v. 98, p. 239-254, DOI: https://doi.org/10.1016/j.rser.2018.09.015. 2018.

IRENA. Renewable energy statistics 2025. International Renewable Energy Agency: Abu Dhabi, 2025.

MISQUITA, I. da S.; ZILLES, R. Soiling accumulation impact on PV modules installed at different tilted angles in São Paulo, Brazil. Journal of Physics: Conference Series. 2180. 012008. DOI:10.1088/1742-6596/2180/1/012008.

NAEEM, U. CHADDA, K.; VAHAJI, S.; AHMAD, J., LI, X., ASADI, E. Aerial Imaging-Based Soiling Detection System for Solar Photovoltaic Panel Cleanliness Inspection. SENSORS 25, no. 3: 738, 2025. DOI:https://doi.org/10.3390/s25030738.

ONS. Sobre o SIN O Sistema em Números: Evolução da Capacidade instalada no SIN - Junho 2026/ Dezembro 2030. Publicado em: 2026. Disponível em: https://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros. Acesso em 15 de junho de 2026.

PADILLA, R., NETTO, S. L., & da SILVA, E. A. B. (2020). A Survey on Performance Metrics for Object-Detection Algorithms. Proceedings of the 2020 International Conference on Systems, Signals and Image Processing (IWSSIP). DOI: 10.1109/IWSSIP48289.2020.9145130.

Revista ARACÊ
ISSN: 2358-2472

PINTO, F. P. M.. Study and characterization of the impacts of soiling on the performance of photovoltaic systems. 2019. 71f. Dissertação (Mestrado Integrado em Engenharia da Energia e do Ambiente) – Faculdade de Ciências – Universidade de Lisboa, Lisboa, 2019.

REDDI, V. J.; CHENG, C.; KANTER, D.; MATTSON, P.; SCHMUELLING, G.; WU, C.-J.; *et al.* (2020). MLPerf Inference Benchmark. Proceedings of the 47th Annual International Symposium on Computer Architecture (ISCA 2020). DOI:10.48550/arXiv.1911.02549.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection. In: 2016 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2016, Las Vegas, NV, USA, p. 779-788. 2016. DOI: 10.1109/CVPR.2016.91.

SANTOS, S. W. Detecção de sujidade e sombreamento em painéis solares com inteligência artificial utilizando aplicativos móveis. 2023. 94 f. Trabalho de Conclusão de Curso (Graduação em Engenharia de Controle e Automação) – Centro de Tecnologia, Universidade Federal de Santa Maria, Santa Maria, RS, 2023.

ZORRILLA-CASANOVA, J.; PILIOUGINE ,M.; RUBIO, J.; BERNAOLA-GALVAN, P . (2011). Analysis of Dust Losses in Photovoltaic Modules. In: WORLD RENEWABLE ENERGY CONGRESS 2011, 2011, Linköping, Sweden. 2985-2992. DOI: 10.3384/ecp110572985.