

## FACE-DETECT: DETECÇÃO FACIAL AUTOMÁTICA EM CENÁRIOS DESAFIADORES

FACE-DETECT: AUTOMATIC FACIAL DETECTION IN CHALLENGE SCENARIOS

FACE-DETECT: DETECCIÓN FACIAL AUTOMÁTICA EN ESCENARIOS DESAFIANTES

Luiz Otávio de Oliveira Souza Júnior<sup>1</sup>

Ricardo Alves Silva<sup>2</sup>

Uriel Werneck de Alcantara<sup>3</sup>

Hamilton de Arruda Souza<sup>4</sup>

Genilson Vieira Martins<sup>5</sup>

João Otávio Bandeira Diniz<sup>6</sup>

**RESUMO:** A detecção facial automática é uma tecnologia fundamental para aplicações de segurança, vigilância inteligente, controle de acesso e monitoramento de ambientes. Entretanto, fatores como oclusões faciais, variações de iluminação, mudanças de escala, diferentes poses e condições não controladas ainda representam desafios significativos para os sistemas de visão computacional. Nesta pesquisa, apresenta-se o Face-Detect, uma abordagem baseada em aprendizado profundo para a detecção automática de faces em cenários desafiadores. A metodologia foi avaliada utilizando os conjuntos de dados Face Obstruction Detection, WIDER FACE e AI Face Dataset, abrangendo situações com máscaras, óculos, múltiplas faces e imagens sintéticas. Foram realizados experimentos com arquiteturas YOLOv8 e YOLOv8n-face, permitindo a comparação entre diferentes estratégias de detecção. Os resultados demonstraram níveis satisfatórios de precisão, robustez e capacidade de generalização, confirmando a viabilidade da abordagem proposta para a detecção facial em cenários desafiadores. As análises realizadas evidenciam o potencial da solução para aplicações em vigilância inteligente, segurança pública e sistemas automatizados de monitoramento.

1

**Palavras-chave:** Visão Computacional. Face. Vigilância. Detecção Automática.

<sup>1</sup>Doutor em Mecatrônica / Professor de Informática – IFBaiano. Fábrica de Inovação Grajaú Instituto Federal do Maranhão (IFMA); Instituto Federal Baiano (IFBaiano).

<sup>2</sup>Aluno de Ensino Superior em Análise e Desenvolvimento de Sistemas – IFMA. Fábrica de Inovação Grajaú – Instituto Federal do Maranhão (IFMA).

<sup>3</sup>Aluno de Ensino Superior em Ciência da Computação – IFMA. Fábrica de Inovação Grajaú Instituto Federal do Maranhão (IFMA).

<sup>4</sup>Especialista em Educação Profissional e Tecnologia / Técnico em Assuntos Estudantis – IFMA. Fábrica de Inovação Grajaú – Instituto Federal do Maranhão (IFMA).

<sup>5</sup>Mestre em Física / Professor de Física. Fábrica de Inovação Grajaú – Instituto Federal do Maranhão (IFMA).

<sup>6</sup>Doutor em Computação / Professor de Informática – IFMA. Fábrica de Inovação Grajaú – Instituto Federal do Maranhão (IFMA).

**ABSTRACT:** Automatic face detection is a key technology for applications involving security, intelligent surveillance, access control, and environmental monitoring. However, factors such as facial occlusions, illumination variations, scale changes, pose diversity, and uncontrolled conditions remain significant challenges for computer vision systems. This paper presents Face-Detect, a deep learning-based approach for automatic face detection in challenging scenarios. The proposed methodology was evaluated using the Face Obstruction Detection, WIDER FACE, and AI Face Dataset benchmarks, covering situations involving masks, glasses, multiple faces, and synthetic images. Experiments were conducted using YOLOv8 and YOLOv8n-face architectures, enabling a comparative analysis of different detection strategies. The results demonstrated satisfactory levels of precision, robustness, and generalization capability, confirming the feasibility of the proposed approach for face detection in challenging scenarios. The analyses performed demonstrate the potential of the solution for applications in intelligent surveillance, public safety, and automated monitoring systems.

**Keywords:** Computer Vision. Face. Surveillance. Automatic Detection.

**RESUMEN:** La detección facial automática es una tecnología fundamental para aplicaciones de seguridad, vigilancia inteligente, control de acceso y monitoreo de entornos. Sin embargo, factores como las oclusiones faciales, las variaciones de iluminación, los cambios de escala, las diferentes poses y las condiciones no controladas siguen representando desafíos importantes para los sistemas de visión por computador. En esta investigación se presenta Face-Detect, un enfoque basado en aprendizaje profundo para la detección automática de rostros en escenarios desafiantes. La metodología fue evaluada utilizando los conjuntos de datos Face Obstruction Detection, WIDER FACE y AI Face Dataset, incluyendo situaciones con mascarillas, gafas, múltiples rostros e imágenes sintéticas. Se realizaron experimentos con las arquitecturas YOLOv8 y YOLOv8n-face, permitiendo comparar diferentes estrategias de detección. Los resultados demostraron niveles satisfactorios de precisión, robustez y capacidad de generalización, confirmando la viabilidad del enfoque propuesto para la detección facial en escenarios desafiantes. Los análisis realizados evidencian el potencial de la solución para aplicaciones en vigilancia inteligente, seguridad pública y sistemas automatizados de monitoreo.

**Palabras clave:** Visión por Computador. Rostro. Vigilancia. Detección Automática.

## INTRODUÇÃO

A face humana é uma das características biométricas mais utilizadas em sistemas de identificação automática devido à sua singularidade e à facilidade de aquisição por dispositivos de captura de imagens, como câmeras de vigilância e dispositivos móveis (JAIN et al., 2011; SHUKLA et al., 2018). Segundo Zhu e Ramanan (2012), elementos faciais específicos, conhecidos como pontos fiduciais, como olhos, nariz e boca, permitem a extração de informações discriminativas utilizadas em processos de detecção, reconhecimento e verificação de identidade. Além dessas características geométricas, atributos texturais, expressões faciais e

representações vetoriais geradas por redes neurais profundas têm ampliado significativamente o potencial dos sistemas biométricos modernos (SHANTHI e NICKOLAS, 2022). De acordo com Ali et al. (2012), a análise facial tornou-se uma ferramenta amplamente empregada em aplicações de segurança pública, investigação forense e autenticação de usuários, contribuindo para processos de verificação, identificação e apoio à tomada de decisão.

A detecção facial automática consolidou-se como uma das tecnologias mais relevantes da atualidade, sendo aplicada em sistemas de segurança, controle de acesso, monitoramento inteligente e análise comportamental (THAHER et al., 2025). Conforme destacado por Apoorva et al. (2019), o avanço dessas tecnologias é impulsionado pela crescente demanda por soluções capazes de identificar indivíduos de forma eficiente em diferentes contextos, contribuindo para o aumento da segurança e da automação em ambientes públicos, privados e corporativos. Nesse cenário, a face humana destaca-se como um identificador confiável devido à sua unicidade e à sua frequente presença em imagens capturadas por sistemas de vigilância, possibilitando a criação de aplicações voltadas à identificação automática de indivíduos com elevados níveis de precisão (NEFIAN et al., 1997).

Apesar dos avanços observados, a detecção facial ainda enfrenta desafios significativos quando aplicada em ambientes não controlados. Em cenários reais, como ruas, praças, estações de transporte público, ambientes corporativos e espaços abertos, fatores como oclusões faciais causadas por máscaras, óculos ou outros objetos, variações de iluminação, diferentes ângulos de visão, mudanças de escala e posicionamentos imprevisíveis dos indivíduos podem comprometer significativamente o desempenho dos sistemas de detecção (AGRAWAL e SINGH, 2017; SOUZA JUNIOR, 2016). Essas limitações tornam necessária a busca por abordagens mais robustas, capazes de manter elevados níveis de desempenho mesmo em condições adversas.

Nesse contexto, a visão computacional, subárea da inteligência artificial dedicada à interpretação automática de imagens e vídeos, tem desempenhado papel fundamental no desenvolvimento de métodos mais eficientes para análise facial. Inicialmente, os sistemas dependiam da extração manual de características, apresentando limitações diante da elevada variabilidade dos dados visuais (CANEDO e NEVES, 2019). Com o avanço do aprendizado profundo, especialmente por meio de redes neurais convolucionais e arquiteturas modernas de detecção de objetos, tornou-se possível aprender representações discriminativas diretamente dos dados, resultando em melhorias expressivas nos sistemas de detecção e reconhecimento

facial (JIANG e LEARNED-MILLER, 2017; THAHER et al., 2025; PEI et al., 2026). Atualmente, essas técnicas representam o estado da arte em aplicações relacionadas ao reconhecimento facial, monitoramento inteligente e identificação automática de indivíduos (SOUZA et al., 2018; LEMOS et al., 2024).

Apesar dos avanços recentes, ainda há limitações relacionadas à detecção facial em cenários com oclusões e elevada variabilidade visual, especialmente quando os modelos são avaliados em bases distintas daquelas utilizadas durante o treinamento. Diante desse contexto, este trabalho apresenta o Face-Detect, uma abordagem automática e robusta para detecção facial baseada em técnicas de visão computacional e aprendizado profundo. As principais contribuições deste estudo consistem no desenvolvimento de uma abordagem baseada nas arquiteturas YOLOv8 e ResNet-18 para detecção facial em cenários desafiadores; na avaliação da solução em três conjuntos de dados públicos amplamente utilizados na literatura, Face Obstruction Detection, WIDER FACE e AI Face Dataset, que contemplam diferentes condições de oclusão, iluminação, pose, escala e complexidade visual, abrangendo imagens sintéticas e cenários reais; e na comparação com o detector especializado YOLOv8n-face, evidenciando desempenho superior em diferentes condições de operação.

## METODOLOGIA

Este estudo utiliza técnicas de visão computacional e aprendizado profundo para a detecção facial automática em cenários desafiadores. O desenvolvimento da abordagem foi realizado por meio da plataforma Ultralytics (2023), que integra etapas de preparação dos dados, treinamento, validação e inferência de modelos de aprendizado de máquina. Foram empregadas as arquiteturas YOLOv8 (GLENN et al., 2023), YOLOv8n-face (DERRONQI, 2025) e ResNet-18 (HE et al., 2016), amplamente utilizadas em tarefas de detecção e classificação de imagens devido à sua eficiência computacional e elevada capacidade de representação de características visuais.

## MATERIAIS

Inicialmente, foi realizada uma revisão da literatura em artigos científicos e materiais especializados relacionados à detecção facial, biometria, visão computacional e aprendizado profundo. Essa etapa permitiu compreender os principais desafios associados à detecção de faces

em ambientes controlados e não controlados, além de fundamentar o desenvolvimento da abordagem proposta.

Para a realização dos experimentos, foram utilizados três conjuntos de dados públicos com características complementares: Face Obstruction Detection (SALARI e ROSTAMI, 2016), AI Face Dataset (SHAVAIZ, 2024) e WIDER FACE (YANG et al., 2023). A seleção desses conjuntos teve como objetivo avaliar a abordagem proposta em diferentes cenários, contemplando desde condições de oclusão facial até imagens sintéticas e ambientes altamente desafiadores encontrados em aplicações reais.

O primeiro deles foi o Face Obstruction Detection, composto por 19.163 imagens distribuídas em seis categorias relacionadas a diferentes tipos de oclusão facial, incluindo óculos, mão, máscara, sem obstrução, outras obstruções e óculos escuros. Devido à diversidade de condições de ocultação da face, esse conjunto foi utilizado para o treinamento e a avaliação inicial da abordagem proposta, permitindo analisar sua capacidade de detectar faces mesmo na presença de obstáculos visuais.

Em seguida, foi utilizado o AI Face Dataset, composto por 3.000 imagens faciais sintéticas selecionadas de uma coleção com aproximadamente 80.000 faces produzidas por modelos generativos avançados. Esse conjunto apresenta ampla diversidade de identidades, características e expressões faciais, sendo empregado para avaliar a capacidade do modelo de operar em condições variadas do modelo em imagens geradas artificialmente e em cenários distintos daqueles utilizados durante o treinamento.

Por fim, para validar a robustez da abordagem em situações mais próximas de aplicações reais, foi empregado o WIDER FACE, um dos principais benchmarks para detecção facial da literatura. O conjunto original possui 32.203 imagens e 393.703 faces anotadas. Neste trabalho, foi utilizada a partição de teste contendo 16.097 imagens. As imagens apresentam elevada variabilidade de pose, escala, iluminação e oclusão, tornando o conjunto de dados particularmente desafiador e adequado para avaliar a adaptação a diferentes cenários e a robustez dos detectores faciais desenvolvidos.

A implementação dos modelos foi realizada em Python por meio da biblioteca PyTorch (PASZKE et al., 2019), utilizando o ambiente Jupyter Notebook para execução dos experimentos. Como etapa de pré-processamento, foram aplicadas técnicas de aumento de dados com o objetivo de ampliar a diversidade das amostras de treinamento e aumentar a

robustez do modelo diante de diferentes condições de entrada. Entre as transformações empregadas destacam-se o redimensionamento das imagens para  $224 \times 224$  pixels, o espelhamento horizontal aleatório (*Random Horizontal Flip*), a conversão para tensor e a normalização baseada nos parâmetros do ImageNet.

As configurações de treinamento adotadas foram: 50 épocas, tamanho de lote de 16 imagens, resolução de entrada de  $224 \times 224$  pixels e taxa de aprendizado de  $1 \times 10^{-4}$ . Todos os experimentos foram executados em um computador equipado com processador Intel Core i7-12700H de 12ª geração (2,30 GHz), 64 GB de memória RAM DDR5, placa gráfica NVIDIA GeForce RTX 3060 Laptop GPU com 6 GB de memória dedicada e sistema operacional Windows 10 Home 64 bits.

## MÉTODOS

A metodologia proposta foi estruturada em três experimentos com o objetivo de avaliar diferentes estratégias de detecção facial e analisar sua capacidade de generalização em cenários desafiadores.

Inicialmente, as imagens passaram por uma etapa de pré-processamento e aumento de dados, visando reduzir os efeitos do desbalanceamento das classes e ampliar a diversidade visual do conjunto de treinamento. Em seguida, foram aplicadas técnicas de aprendizado profundo voltadas para a detecção automática de faces em imagens 2D.

No Experimento 1, foi desenvolvido um modelo próprio utilizando o detector YOLOv8 com pesos pré-treinados (yolov8n.pt) em conjunto com a arquitetura ResNet-18 para classificação. O treinamento foi realizado utilizando o dataset Face Obstruction Detection, dividido em 60% para treinamento, 20% para validação e 20% para teste. O desempenho foi avaliado por meio das métricas Precision, Recall, F1-score e Accuracy.

No Experimento 2, o modelo desenvolvido foi aplicado aos conjuntos AI Face Dataset e WIDER FACE Test, com o objetivo de investigar desempenho em bases distintas da utilizada durante o treinamento.

No Experimento 3, foi empregado o modelo YOLOv8n-face, especializado em detecção facial, também avaliado nos conjuntos AI Face Dataset e WIDER FACE Test. Os resultados obtidos foram comparados aos do modelo proposto, permitindo analisar diferentes estratégias

de detecção facial em cenários caracterizados por oclusões, múltiplas faces, variações de iluminação e diferentes poses.

Por fim, os resultados quantitativos e qualitativos obtidos em cada experimento foram analisados para verificar a robustez e a precisão das abordagens avaliadas na tarefa de detecção facial automática.

## RESULTADOS E DISCUSSÃO

Os resultados obtidos no primeiro experimento são consistentes com a literatura recente sobre detecção facial, no qual teve como objetivo avaliar o desempenho do modelo proposto no conjunto Face Obstruction Detection, composto por imagens contendo diferentes tipos de oclusão facial. Os resultados obtidos demonstraram valores de Precision de 89,85%, Recall de 82,59%, F1-score de 86,07% e Accuracy de 75,54%, evidenciando a capacidade do modelo em detectar faces mesmo na presença de obstáculos visuais como máscaras, óculos, óculos escuros e mãos.

O valor superior de Precision indica que a maior parte das detecções realizadas correspondeu efetivamente a faces presentes nas imagens, reduzindo a ocorrência de falsos positivos. O Recall obtido demonstra que o modelo foi capaz de localizar a maioria das faces disponíveis no conjunto de dados, enquanto o F1-score evidencia um equilíbrio satisfatório entre precisão e revocação. Em conjunto, esses resultados indicam que a estratégia de treinamento adotada foi eficiente para lidar com diferentes níveis de oclusão facial, condição frequentemente encontrada em aplicações reais de vigilância e monitoramento.

No segundo experimento, o modelo treinado foi avaliado nos conjuntos AI FACE DATASET e WIDER FACE Test, com o objetivo de analisar sua eficácia em cenários variados daqueles utilizados durante o treinamento. Os resultados mostraram confiança média de 0,8557 no AI FACE DATASET e 0,7202 no WIDER FACE Test.

O desempenho superior observado no AI Face Dataset pode estar relacionado às características das imagens sintéticas presentes nesse conjunto de dados, que tendem a apresentar maior uniformidade visual e menor variabilidade de fatores que dificultam a detecção facial. Esse comportamento está alinhado a estudos recentes que apontam que imagens sintéticas frequentemente apresentam menor incidência de ruídos, oclusões e variações ambientais quando comparadas a cenários reais, favorecendo o desempenho dos detectores

faciais. Em contrapartida, o WIDER FACE Test apresenta condições significativamente mais desafiadoras, incluindo múltiplas faces, variações de escala, diferentes poses e oclusões parciais, fatores que impactam diretamente a confiança das detecções. Apesar dessas dificuldades, o modelo manteve níveis satisfatórios de desempenho, evidenciando a consistência das detecções e adaptação a diferentes contextos visuais.

No terceiro experimento, foi avaliado o desempenho do modelo YOLOv8n-face nos mesmos conjuntos utilizados no Experimento 2, permitindo uma comparação direta com a abordagem proposta. Os resultados indicaram confiança média de 0,8109 no AI FACE DATASET e 0,6962 no WIDER FACE Test, demonstrando desempenho consistente em ambos os cenários avaliados.

Embora o YOLOv8n-face seja um detector facial especializado, os valores obtidos foram inferiores aos observados para o modelo proposto. Essa diferença sugere que a abordagem desenvolvida neste trabalho foi mais eficiente na adaptação às características dos conjuntos avaliados, especialmente em situações envolvendo oclusões e elevada variabilidade visual. A comparação entre os Experimentos 2 e 3 evidencia que o modelo proposto apresentou maior confiança média nas duas bases analisadas, alcançando ganhos de aproximadamente 5,5% no AI FACE DATASET e 3,4% no WIDER FACE Test em relação ao YOLOv8n-face.


De forma geral, os resultados obtidos nos três experimentos demonstram que a abordagem proposta apresenta desempenho competitivo para a tarefa de detecção facial automática. A superioridade observada em relação ao YOLOv8n-face e o desempenho consistente em bases externas reforçam o potencial da solução para aplicações em vigilância inteligente, segurança pública e sistemas automatizados de monitoramento.

Complementando a análise quantitativa, foram realizadas avaliações qualitativas com o objetivo de investigar visualmente o comportamento dos modelos em diferentes condições de oclusão, escalas e complexidades visuais. As figuras a seguir apresentam exemplos representativos das detecções obtidas nos quatro experimentos, permitindo uma análise mais detalhada da capacidade dos modelos em localizar corretamente faces e pessoas em cenários desafiadores.

Conforme apresentado no Experimento 1, foi realizada uma análise qualitativa utilizando imagens representativas das seis categorias do conjunto Face Obstruction Detection, correspondentes a: (a) óculos transparentes, (b) mão cobrindo parcialmente a face, (c) outras

oclusões, (d) óculos escuros, (e) máscara facial e (f) sem obstrução. Os resultados demonstram que o modelo foi capaz de detectar corretamente as faces em todas as categorias avaliadas, incluindo cenários com diferentes tipos e níveis de oclusão. Mesmo na presença de acessórios ou objetos que ocultam parcialmente a região facial, as faces foram localizadas de forma adequada, evidenciando a capacidade do modelo em extrair características discriminativas relevantes em condições adversas. Esses resultados qualitativos corroboram as métricas quantitativas obtidas no Experimento 1 e reforçam a robustez da abordagem proposta para aplicações de detecção facial em ambientes desafiadores. A Figura 1 apresenta exemplos representativos das imagens originais e dos respectivos resultados de detecção obtidos pelo modelo proposto.

**Figura 1** – Análise qualitativa dos resultados obtidos do experimento 1 utilizando o modelo proposto no conjunto Face Obstruction Detection. A primeira linha apresenta as imagens originais, enquanto a segunda linha mostra os resultados das detecções realizadas pelo modelo.



**Fonte:** Elaboração própria (2026), dados extraídos de Face Obstruction Detection (SALARI e ROSTAMI, 2016).

A análise qualitativa do Experimento 2 foi realizada utilizando os conjuntos de dados WIDER FACE Test e AI Face Dataset, com o objetivo de analisar a capacidade de adaptação a diferentes cenários do modelo proposto em cenários distintos daqueles utilizados durante o treinamento. Foram analisadas imagens contendo múltiplas faces, diferentes escalas e variados níveis de complexidade visual. Os resultados demonstram que o modelo foi capaz de localizar corretamente as faces presentes nas imagens, mantendo desempenho consistente mesmo em condições desafiadoras, o que corrobora os resultados quantitativos obtidos para ambos os

conjuntos de dados. Exemplos representativos das detecções realizadas são apresentados na Figura 2.

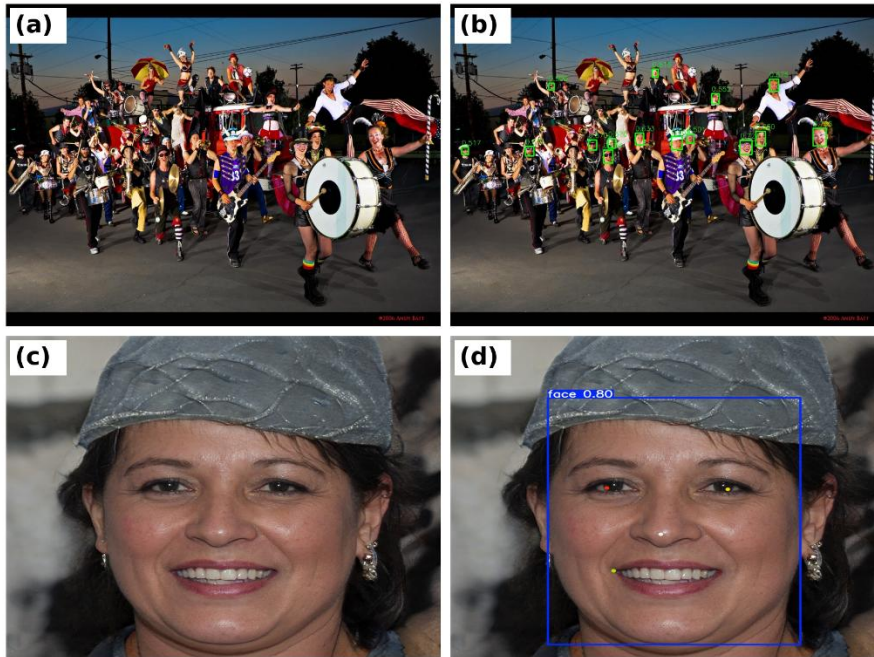
**Figura 2** – Resultados qualitativos do Experimento 2. (a) imagem original do WIDER FACE, (b) resultado da detecção no WIDER FACE, (c) imagem original do AI FACE DATASET e (d) resultado da detecção no AI FACE DATASET.



**Fonte:** Elaboração própria (2026), dados extraídos de WIDER FACE (YANG et al., 2023) e AI Face Dataset (SHAVAIZ, 2024).

Conforme apresentado no Experimento 3, foi realizada uma análise qualitativa utilizando os conjuntos de dados WIDER FACE Test e AI Face Dataset, empregando o modelo YOLOv8n-face. Os resultados demonstram que o detector foi capaz de localizar corretamente as faces presentes nas imagens, mesmo em cenários caracterizados por múltiplos indivíduos, diferentes escalas, variações de pose e condições visuais distintas. Observou-se que o modelo manteve desempenho consistente em ambos os conjuntos de dados, evidenciando sua robustez em cenários distintos daqueles utilizados durante o treinamento. Esses resultados qualitativos corroboram os resultados quantitativos obtidos no Experimento 3 e reforçam a eficiência do YOLOv8n-face para tarefas de detecção facial em cenários variados. A Figura 3 apresenta exemplos representativos das detecções realizadas pelo modelo nos conjuntos de dados avaliados.

**Figura 3** - Resultados qualitativos do Experimento 3 utilizando o modelo YOLOv8n-face. Os exemplos correspondem a: (a) imagem original do WIDER FACE Test, (b) resultado da detecção realizada pelo YOLOv8n-face no WIDER FACE Test, (c) imagem original do AI FACE DATASET e (d) resultado da detecção realizada pelo YOLOv8n-face no AI FACE DATASET.



**Fonte:** Elaboração própria (2026), dados extraídos de WIDER FACE (YANG et al., 2023) e AI Face Dataset (SHAVAIZ, 2024).

De forma geral, os resultados quantitativos e qualitativos demonstram que o Face-Detect apresenta desempenho robusto e capacidade de generalização para a tarefa de detecção facial automática. Os resultados obtidos nos conjuntos Face Obstruction Detection, WIDER FACE Test e AI Face Dataset evidenciam a eficácia da abordagem proposta em cenários caracterizados por oclusões faciais, múltiplas faces, variações de iluminação, diferentes poses e imagens sintéticas. O desempenho alcançado no Experimento 1 sugere que o treinamento realizado com diferentes tipos de oclusão facial contribuiu significativamente para a robustez do modelo, refletindo positivamente nos resultados observados nos Experimentos 2 e 3. Essa característica permitiu que a abordagem mantivesse níveis satisfatórios de desempenho mesmo em cenários distintos daqueles utilizados durante o treinamento. Além disso, o desempenho superior ao modelo YOLOv8n-face reforça o potencial da solução para aplicações em vigilância inteligente, segurança pública, controle de acesso e monitoramento automatizado.

## CONSIDERAÇÕES FINAIS

A análise dos resultados obtidos evidencia que o Face-Detect representa uma abordagem eficaz para a detecção facial automática em cenários desafiadores. A avaliação realizada por meio de três conjuntos de dados públicos: Face Obstruction Detection, WIDER FACE e AI Face Dataset, demonstrou de forma consistente que técnicas baseadas em aprendizado profundo são capazes de manter níveis satisfatórios de precisão, robustez e adaptação a diferentes cenários mesmo diante de condições adversas, como oclusões faciais, variações de iluminação, múltiplas faces, diferentes poses e imagens sintéticas. Esses resultados confirmam a viabilidade da abordagem proposta e reforçam seu potencial para aplicações em vigilância inteligente, segurança pública, controle de acesso e monitoramento automatizado.

Apesar dos resultados promissores, a aplicação dessas tecnologias em ambientes reais ainda requer avaliações adicionais em cenários mais complexos e diversificados. A ampliação dos experimentos para novos conjuntos de dados e condições operacionais poderá fornecer uma análise mais abrangente da robustez, da escalabilidade e da capacidade de adaptação da solução. Nesse sentido, o Face-Detect estabelece uma alternativa promissora para futuras pesquisas em reconhecimento facial, possibilitando a integração de mecanismos de identificação automática de indivíduos em sistemas inteligentes. Como trabalhos futuros, pretende-se ampliar a avaliação da abordagem em novos conjuntos de dados, realizar testes em fluxos de vídeo em tempo real e investigar estratégias avançadas de reconhecimento facial, com o objetivo de aumentar a robustez, a escalabilidade e a aplicabilidade da solução em cenários reais.

## AGRADECIMENTOS E FINANCIAMENTO

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Os autores agradecem ao Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA) e à Fundação de Amparo à Pesquisa e ao Desenvolvimento Científico e Tecnológico do Maranhão (FAPEMA) pelo apoio institucional e financeiro à pesquisa. Agradecem, ainda, à Fábrica de Inovação do IFMA – Campus Grajaú pela disponibilização da infraestrutura, dos recursos tecnológicos e do ambiente de desenvolvimento que viabilizaram a execução deste estudo e o desenvolvimento da abordagem proposta.

## REFERÊNCIAS

ADAM PASZKE, Sam; GROSS, Sam; MASSA, Francisco; LERER, Adam; BRADBURY, James; CHANAN, Gregory; KILLEEN, Trevor; LIN, Zeming; GIMELSHEIN, Natalia; ANTIGA, Luca et al. Pytorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, v. 32, 2019.

AGRAWAL, Amrit Kumar; SINGH, Yogendra Narain. An efficient approach for face recognition in uncontrolled environment. *Multimedia Tools and Applications*, v. 76, n. 3, p. 3751–3760, 2017.

ALI, Tauseef; SPREEUWERS, Luuk; VELDHUIS, Raymond. Forensic face recognition: A survey. In: *Face Recognition: Methods, Applications and Technology*. Nova Publishers, 2012. p. 9.

APOORVA, P. et al. Automated criminal identification by face recognition using open computer vision classifiers. In: *2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)*. IEEE, 2019. p. 775–778.

CANEDO, Daniel; NEVES, António JR. Facial expression recognition using computer vision: A systematic review. *Applied Sciences*, v. 9, n. 21, p. 4678, 2019.

DERRONQI. YOLOv8n-face: Face Detection based on YOLOv8. GitHub, 2024. Disponível em: <https://github.com/derronqi/yolov8-face>. Acesso em: 25 maio 2026.

GLENN JOCHER; CHAURASIA, Ayush; QIU, Jing. Ultralytics YOLOv8. 2023. Disponível em: <https://docs.ultralytics.com/pt/models/yolov8>. Acesso em: 25 maio 2026.

HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. Deep residual learning for image recognition. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016. p. 770–778.

JAIN, Anil; BOLLE, Ruud; PANKANTI, Sharath. Introduction to biometrics. In: *Biometrics: Personal Identification in Networked Society*. Boston, MA: Springer US, 2011. p. 1–41.

JIANG, Huaizu; LEARNED-MILLER, Erik. Face detection with the Faster R-CNN. In: *2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017)*. IEEE, 2017. p. 650–657.

LEMOS, Rodrigo Pinto et al. Sistema de controle de acesso através de reconhecimento facial com monitoramento remoto. *Revista Brasileira Militar de Ciências*, v. 10, n. 24, 2024.

NEFIAN, Ara V.; KHOSRAVI, Mehdi; HAYES III, Monson H. Real-time detection of human faces in uncontrolled environments. In: *Visual Communications and Image Processing '97*. SPIE, 1997. p. 211–219.

PEI, Gan et al. Deepfake generation and detection: A benchmark and survey. *ACM Computing Surveys*, v. 58, n. 11, p. 1–41, 2026.

SALARI, Seyed Reza; ROSTAMI, Habib. Pgu-Face: A dataset of partially covered facial images. Mendeley Data, v. 1, 2016. Disponível em: <https://www.kaggle.com/datasets/janwidziski/face-obstructions?resource=download>. Acesso em: 02 dez. 2025.

SHANTHI, P.; NICKOLAS, S. Facial landmark detection and geometric feature-based emotion recognition. *International Journal of Biometrics*, v. 14, n. 2, p. 138–154, 2022.

SHAVAIZ, Muhammad. AI Face Dataset. 2024. Disponível em: <https://www.kaggle.com/datasets/shavaizbutt/ai-face-dataset-3000-images>. Acesso em: 02 dez. 2025.

SHUKLA, Ratnesh Kumar; AGARWAL, Ajay; MALVIYA, Anil Kumar. An introduction of face recognition and face detection for blurred and noisy images. *International Journal of Scientific Research in Computer Science and Engineering*, v. 6, n. 3, p. 39–43, 2018.

SOUZA JUNIOR, Luiz Otávio de Oliveira. Um estudo sistemático sobre detecção de impostor facial. Dissertação (Mestrado) – Universidade Federal da Bahia, Salvador, 2016.

SOUZA, Luiz et al. How far did we get in face spoofing detection? *Engineering Applications of Artificial Intelligence*, v. 72, p. 368–381, 2018.

THAHER, T.; MAFARJA, M.; SAFFARINI, M. et al. A Comprehensive Review of Face Detection Techniques for Occluded Faces: Methods, Datasets, and Open Challenges. *Computer Modeling in Engineering & Sciences*, v. 143, n. 3, p. 2615–2673, 2025.

ULTRALYTICS. Models Supported by Ultralytics. 2023. Disponível em: <https://docs.ultralytics.com/pt/models>. Acesso em: 25 maio 2026.

YANG, Shuo; LUO, Ping; LOY, Chen Change; TANG, Xiaoou. WIDER FACE. 2023. Disponível em: <https://www.kaggle.com/datasets/iamprateek/wider-face-a-face-detection-dataset>. Acesso em: 02 dez. 2025.

ZHU, Xiangxin; RAMANAN, Deva. Face detection, pose estimation, and landmark localization in the wild. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2012. p. 2879–2886.