

Visão Computacional: detecção de armas utilizando YOLO V8

Marcos Reges Mota
Instituto de Informática
UFG
Goiânia, Brasil
regesmota@discente.ufg.br

Ana Luísa Chagas
Instituto de Informática
UFG
Goiânia, Brasil
analuisa23@discente.ufg.br

Maurício Rodrigues Lima
Instituto de Informática
UFG
Goiânia, Brasil
k20x@outlook.com

Elisângela Silva Dias
Instituto de Informática
UFG
Goiânia, Brasil
elisangelasd@ufg.br

Abstract—This study examines the application of YOLOv8 for weapon detection in security-sensitive environments. Using an annotated dataset containing various firearm types under diverse conditions, we implemented the yolov8s configuration to optimize both detection accuracy and computational efficiency. Results demonstrate particularly strong detection capabilities for certain weapon categories, while maintaining reliable performance across all classes. These findings suggest YOLOv8's significant potential for security applications, offering improvements over previous detection methods in both accuracy and processing speed. The model's balanced performance makes it particularly suitable for environments where rapid and reliable threat identification is crucial.

Keywords—YoloV8; Gun-Detection; Deep Learning.

Resumo—Este estudo examina a aplicação do YOLOv8 para a detecção de armas em ambientes sensíveis à segurança. Utilizando um conjunto de dados anotado contendo diversos tipos de armas de fogo em diferentes condições, foi implementada a configuração yolov8s para otimizar tanto a precisão da detecção quanto a eficiência computacional. Os resultados demonstram capacidades particularmente fortes de detecção para certas categorias de armas, mantendo um desempenho confiável em todas as classes. Esses achados sugerem um potencial significativo do YOLOv8 para aplicações de segurança, oferecendo melhorias em relação aos métodos anteriores tanto em precisão quanto em velocidade de processamento. O desempenho equilibrado do modelo o torna especialmente adequado para ambientes onde a identificação rápida é crucial.

Palavras-chave—YoloV8; Detecção de Armas; Aprendizado Profundo.

I. INTRODUÇÃO

Nos últimos anos, o aumento de incidentes violentos envolvendo armas de fogo em instituições de ensino tem intensificado a preocupação global com a segurança no ambiente escolar. Esses eventos representam uma ameaça direta à integridade física de estudantes, professores e demais profissionais da educação, além de acarretarem impactos psicológicos duradouros nos sobreviventes. Indivíduos expostos a traumas relacionados a armas de fogo podem apresentar dificuldades

de aprendizado e desenvolver transtornos psicológicos, como ansiedade, depressão e transtorno de estresse pós-traumático [1].

A violência cometida com armas de fogo exerce um impacto significativo nos custos públicos, de saúde, psicológicos e econômicos. Muitas pessoas morrem anualmente em decorrência de episódios violentos envolvendo armas. O trauma psicológico é frequente entre crianças expostas a altos níveis de violência em suas comunidades ou por meio da mídia. Crianças expostas à violência armada, sejam elas vítimas, agressores ou testemunhas, podem sofrer efeitos psicológicos negativos tanto a curto quanto a longo prazo [2].

Os índices de violência com armas de fogo variam substancialmente entre diferentes localidades e países, podendo chegar a até 1.000 mortes por dia em escala global [3]. A identificação de comportamentos disruptivos em estágio inicial, aliada ao monitoramento cuidadoso de atividades suspeitas, pode reduzir a criminalidade, permitindo que as agências de segurança pública tomem medidas imediatas [4].

A visão computacional, um subcampo da inteligência artificial, tem se destacado pela capacidade de analisar e interpretar imagens com alta precisão [5], possibilitando o desenvolvimento de sistemas automatizados para detecção de objetos em tempo real.

Entre os modelos de detecção de objetos, o YOLO V8, versão mais recente da arquitetura YOLO (You Only Look Once), oferece suporte a tarefas de detecção, classificação e segmentação. Este estudo investiga a aplicação do YOLO V8 na identificação de armas de fogo, utilizando um conjunto de imagens de teste obtidas em diferentes condições e com distintos tipos de armamento.

A avaliação do desempenho do modelo foi realizada por meio de métricas como precisão, revocação (recall), F1-Score e mAP (mean Average Precision). Lançado em janeiro de 2023 pela Ultralytics [6], o YOLO V8 tem demonstrado superioridade em relação aos seus predecessores.

O estudo de [7] compara os modelos YOLO da versão 1 até a 8, demonstrando que o YOLOv8 atinge 280 FPS (medido com TensorRT em uma GPU Nvidia A100), superando todos os YOLO anteriores, que alcançavam até 200 FPS (YOLO V5). Além disso, o YOLOv8 mantém alto desempenho e é mais simples de treinar e adaptar, em comparação a versões que exigem definição manual ou heurísticas para anchors (v2 até v5, por exemplo).

Essa nova versão também adota ajustes de perdas (como CIOU + DFL), contribuindo para prever bounding boxes com maior estabilidade e convergência rápida. A adoção de uma arquitetura anchor-free e de ajustes na forma de previsão (combinando CIOU, DFL etc.) simplifica a configuração do modelo em relação às versões anteriores que dependiam de anchor boxes definidos ou de heurísticas.

Este estudo está organizado da seguinte forma: a Seção 2 apresenta a revisão da literatura e discute trabalhos relacionados ao tema, exibidos em uma tabela com algumas de suas principais características. A Seção 3 descreve a metodologia empregada, apresentando o treinamento, métodos de avaliação cruzada e validação do YOLO V8. A Seção 4 expõe os resultados obtidos e suas representações gráficas, como matriz de confusão e curvas. Por fim, a Seção 5 apresenta as conclusões e considerações finais do estudo, além de recomendações para pesquisas futuras.

II. REVISÃO DA LITERATURA

Em um estudo anterior, foi conduzida uma revisão sistemática da literatura [8] com o objetivo de mapear a aplicação de visão computacional à segurança em ambientes educacionais. Dos 10519 artigos inicialmente recuperados em dez bases de dados internacionais, apenas 13 atenderam aos critérios de elegibilidade, o que evidencia a incipiência do tema na literatura especializada.

A síntese desses trabalhos (Tabela I) mostra o predomínio de arquiteturas da família *You Only Look Once* (YOLO) — notadamente as versões v3, v4, v5 e v7 — em razão do bom compromisso entre precisão e velocidade de inferência. Por exemplo, o sistema *SaveLives* baseado em YOLOv4 alcançou *mAP* de 90,35 % em vídeos de locais públicos [9], enquanto a otimização do Scaled-YOLOv4 atingiu 92,1 % de *mAP* com 85,7 FPS em circuitos CCTV [10]. Em contextos propriamente escolares, Ritharson *et al.* integraram YOLOv3 a reconhecimento facial e obtiveram 96 % de precisão e 94 % de *recall* [11]; já Vallez *et al.* empregaram um autoencoder profundo acoplado ao detector para reduzir em 37,9 % a taxa de falsos positivos sem perda de desempenho [12].

Cabe destacar que trabalhos mais recentes fora do domínio educacional já demonstram o potencial do YOLOv8: O estudo [13] implementa um sistema de vigilância que combina

YOLOv8 a notificações por e-mail e relataram acurácia de 94 % na detecção de armas em múltiplos cenários. Do mesmo modo, estudos explorando visão noturna com YOLOv4 [14] e detecção em condições adversas com YOLOv7 [15] reforçam a tendência de empregar versões mais recentes do modelo para reduzir falsos alarmes e ampliar a robustez.

TABELA I
TRABALHOS RELACIONADOS [8]

No.	Método	Cenário	Métricas	Resultados
[9]	Yolov4	Locais públicos	mAP e IOU	mAP: 90.35%, IOU: 73.68%
[10]	Scaled-YOLOv4	Locais públicos monitorados por CCTV	mAP	mAP: 92.1%, FPS: 85.7
[11]	CNN, YOLOv3, HAAR cascade classifier	Escolas	Precisão, Recall	Precisão: 96%, Recall: 94%
[16]	YOLOv3, YOLOv5	Locais públicos	Precisão, Recall	Precisão: 92.2%, Recall: 85.3%
[12]	YOLOv4	Áreas urbanas	Acurácia, Recall	Acurácia: 93.7%, Recall: 90.1%
[15]	CNN, YOLOv7	Locais públicos	Precisão, Recall	Precisão: 95.78%, Recall: 96.92%
[14]	YOLOv4, Visão noturna	Áreas externas noturnas	Precisão, Recall	Precisão: 94%, Recall: 92%

Diferentemente dos estudos enumerados na Tabela I, que empregam, em sua maioria, versões anteriores do YOLO (v3, v4 ou variações escaladas) ou arquiteturas baseadas em CNN [9]–[12], [14]–[16], o presente trabalho adota o YOLOv8, uma arquitetura *anchor-free* que incorpora perdas CIOU e DFL, resultando em maior estabilidade na regressão das *bounding boxes* e convergência mais rápida [6], [7]. Além disso, enquanto as pesquisas anteriores costumam avaliar seus modelos em conjuntos restritos de imagens ou cenários específicos, por exemplo, apenas *Closed-Circuit Television* (CCTV, Circuito Fechado de Televisão) ou ambiente escolar. Este estudo utiliza o *Weapon Detection Dataset* do *Roboflow Universe*, que reúne quatro classes de armamentos capturadas sob variadas

condições de iluminação, ângulos e oclusões [17]. Para garantir robustez, empregamos validação cruzada *5-fold* e analisamos métricas como *F1-Score*, precisão, revocação e *mAP*, abordagem metodológica não relatada de forma sistemática nos trabalhos anteriores. Assim, o presente estudo preenche a lacuna apontada pela revisão sistemática de [8], ao investigar a eficácia do YOLOv8 em um cenário mais amplo e com avaliação experimental rigorosa, oferecendo evidências de ganhos tanto em desempenho quanto em eficiência computacional.

III. FUNDAMENTAÇÃO TEÓRICA

O algoritmo *You Only Look Once* (YOLO) foi introduzido em 2016 como uma abordagem de detecção de objetos que transforma o problema em uma única etapa de regressão, realizando simultaneamente a predição da classe e das coordenadas do *bounding box*. As evoluções subsequentes — da versão v1 até as atuais v8 e v9 — incorporaram extratores de características mais profundos (Darknet-53, CSPDarknet, GELAN) e camadas de detecção em múltiplas escalas, aumentando a sensibilidade a objetos pequenos sem sacrificar desempenho. Em testes extensivos com 51 000 imagens de armas de fogo, YOLOv5s, 7x, 8s e 9c atingiram *mAP @ 0.5* superiores a 96% com até 95 FPS em GPUs de baixo custo, confirmando a viabilidade para aplicações de vigilância em tempo real [18].

Estudos específicos sobre detecção de armas demonstram que YOLOv3 já alcançava precisões acima de 94% e reduzia significativamente falsos positivos em vídeos de baixa resolução, tornando-se opção robusta para sistemas de segurança perimetral [19]. Pesquisas posteriores destacaram ganhos substantivos de eficiência: YOLO-v5s, por exemplo, reduziu o tempo de inferência em cerca de dezessete vezes em relação ao *Faster-RCNN*, mantendo *F1-score* superior a 0.84 em fluxos de vídeo contínuo [20].

Integrações de YOLO com serviços de notificação demonstram a construção de pipelines completos de resposta a incidentes. Implementações que combinam YOLOv3 com disparo de alarmes sonoros e envio de alertas por *e-mail* mostraram tempos de resposta adequados para cenários de vigilância comercial [13], [21]. Em paralelo, abordagens recentes exploraram conjuntos de dados heterogêneos com variações de iluminação, oclusões e diferentes ângulos de câmera; o *fine-tuning* resultante preservou a precisão acima de 90% mesmo em câmeras de circuito interno com resolução limitada [22].

IV. METODOLOGIA

Para a avaliação do modelo YOLOv8, foi utilizado o conjunto de dados disponível no *Roboflow Universe*, especificamente o *Weapon Detection Dataset* [17], acessível em <https://universe.roboflow.com/rhackathon/weapon-detection-aoxpz>. Esse conjunto consiste em uma

coleção diversificada de imagens contendo armas brancas e armas de fogo, elaborada especificamente para o treinamento de modelos de detecção de objetos. As imagens estão anotadas com caixas delimitadoras que indicam com precisão a localização das armas nos quadros, permitindo ao modelo distinguir e classificar os objetos de forma eficaz em uma das quatro categorias predefinidas: “granada”, “faca”, “pistola” ou “rifle”.

Para garantir um equilíbrio entre a precisão de detecção e a eficiência computacional, foi utilizada a configuração *yolov8s.pt* do YOLOv8, uma versão mais leve do modelo, otimizada para desempenho em tempo real, mantendo simultaneamente um alto nível de precisão. Essa escolha foi motivada pela necessidade de processamento rápido, sem comprometer a confiabilidade da detecção, especialmente em aplicações sensíveis à segurança, nas quais respostas imediatas são fundamentais. A diversidade do conjunto de dados — que abrange variações nas condições de iluminação, orientações dos objetos e oclusões — proporcionou uma base sólida para avaliar a capacidade de generalização do modelo em diferentes cenários.

A. Treinamento

O treinamento foi conduzido seguindo as especificações:

- Épocas: 100;
- Tamanho do lote (batch size): 16;
- Tamanho da imagem: 800x800 pixels;
- Taxa de aprendizado: 0,01 com fator de redução para 0,01 após o período de aquecimento (warm-up);
- Otimizador: Automático (seleção automática do melhor otimizador pela ferramenta/framework);
- Pré-treinamento: Verdadeiro (uso de pesos pré-treinados para acelerar o treinamento).

B. Métricas de Avaliação

Para avaliar a eficácia do modelo, foram utilizadas as seguintes métricas:

- Precisão (Precision): Exatidão na identificação correta dos objetos.
- Revocação (Recall): Capacidade do modelo em identificar todas as instâncias relevantes.
- F1-Score: Média harmônica entre a precisão e a revocação.
- *mAP* (mean Average Precision): Média da precisão média considerando diferentes limites (*thresholds*) de IoU (*Intersection over Union*).

$$\text{Precisão: } \frac{VP}{VP + FP}, \quad (1)$$

$$\text{Recall: } \frac{VP}{VP + FN}, \quad (2)$$

$$F1 = \frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}, \quad (3)$$

$$mAP = \frac{1}{n} \sum_{k=1}^n AP_k, \quad (4)$$

Onde TP são os verdadeiros positivos (true positives), FP são os falsos positivos (false positives), FN são os falsos negativos (false negatives) e AP_k é a precisão média (average precision) da classe k . O código para realizar a classificação e avaliação das métricas aqui reportadas foi desenvolvido utilizando *Python* 3.10.12 [23], com a biblioteca proprietária do YOLOv8.

C. Validação

Para obter uma avaliação confiável da capacidade de generalização do modelo construído, foi utilizada uma técnica conhecida como *validação cruzada* (*cross-validation*). O objetivo é garantir que o modelo consiga prever corretamente dados não vistos durante o treinamento, e não apenas realizar previsões precisas em dados já conhecidos.

A técnica escolhida foi o *5 K-fold*, na qual o conjunto total de dados é dividido em 5 grupos disjuntos. No *5 K-fold*, o modelo utiliza quatro grupos para a fase de treinamento e um grupo para a fase de teste. Iterações subsequentes são realizadas variando-se qual grupo será utilizado para treinamento/teste, de forma que cada *fold* seja utilizado como grupo de teste uma única vez. A Figura 1 ilustra esse processo, sendo que cada linha da matriz representa uma iteração distinta:




Fig. 1. Representação gráfica do 5 K-fold

Assim, ao final das cinco iterações, o resultado reportado corresponde à média dos resultados obtidos em cada uma das repetições.

V. RESULTADOS

Para avaliar o desempenho do algoritmo, foram consideradas métricas como precisão, revocação e *F1-score*, garantindo uma análise abrangente da eficácia do sistema proposto. Os testes foram realizados sobre um conjunto de imagens abrangendo diferentes condições e tipos de armas, permitindo uma avaliação robusta do modelo. Os resultados obtidos estão ilustrados nas Figuras 2, 3, 4 e 5.




Fig. 2. Matriz de Confusão

A Figura 3 apresenta a curva F1-Confiança para as classes analisadas: granada, faca, pistola e rifle. A métrica *F1-score* é uma medida combinada de precisão e revocação (*recall*), oferecendo uma visão equilibrada do desempenho do modelo em diferentes níveis de confiança.




Fig. 3. Curva F1-Confiança

Observa-se que a classe granada mantém bom desempenho, com um alto *F1-score* ($> 0,8$) na maior parte dos níveis de confiança. Esse comportamento indica que o modelo é capaz de identificar com precisão e revocação elevadas essa classe, mesmo quando a confiança não é máxima. Por outro lado, as classes faca, pistola e rifle apresentam desempenho inferior, com picos em torno de 0,6-0,7 que decrescem à medida que a confiança aumenta. A média de todas as classes atinge um *F1-score* de 0,74 para um nível de confiança de 0,420, refletindo um bom desempenho geral do modelo.

A Figura 4 ilustra a curva Precisão-Confiança, que revela a relação entre a precisão do modelo e a confiança para as diferentes classes.




Fig. 4. Curva Precisão-Confiança

Nesta curva, novamente destaca-se a classe granada, exibindo uma curva que mantém alta precisão em níveis elevados de confiança. As classes faca, pistola e rifle apresentam desempenho inferior, mas ainda assim exibem uma tendência crescente à medida que a confiança aumenta. A curva média de todas as classes, representada em azul espessa, atinge uma precisão de 1,00 com confiança de 0,953, indicando que, em média, o modelo apresenta elevada precisão quando opera com alta confiança.

As Figuras 5 e 6 apresentam, respectivamente, as curvas Precisão-Revocação e Revocação-Confiança. Na Figura 5, a curva Precisão-Revocação destaca a relação entre precisão e revocação para as diferentes classes. A classe granada apresenta desempenho excepcional, mantendo uma precisão de 0,926 com o aumento da revocação. As classes faca, pistola e rifle exibem quedas mais rápidas na precisão à medida que a revocação aumenta, ainda que mantenham valores razoáveis de precisão (0,706, 0,729 e 0,700, respectivamente). A média geral das classes resulta em um desempenho global satisfatório.




Fig. 5. Curva Precisão-Revocação

A Figura 6 ilustra a curva Revocação-Confiança, mostrando como a revocação varia com a confiança do modelo. A classe granada mantém uma revocação alta (superior a 0,8) ao longo de uma ampla faixa de confiança, indicando que o modelo pode identificar corretamente essa classe mesmo com confiança elevada. Já as classes faca, pistola e rifle apresentam revocação inferior, especialmente a classe rifle, cuja revocação cai para valores abaixo de 0,4 à medida que a confiança aumenta. A revocação média para todas as classes atinge 0,85 com confiança igual a 0,0, mas diminui significativamente à medida que a confiança cresce.




Fig. 6. Curva Revocação-Confiança

Assim, os resultados indicam que o modelo apresenta desempenho sólido, especialmente para a classe “granada”, que se destaca de maneira consistente em todas as métricas analisadas. As demais classes, embora apresentem desempenho inferior, ainda obtêm resultados aceitáveis dentro de uma faixa

razoável de confiança. A média geral do modelo é positiva, pois apresenta altos valores de precisão e revocação em níveis moderados de confiança, refletindo sua eficácia em equilibrar esses aspectos de forma eficiente.

A avaliação do modelo YOLOv8 para a detecção de armas mostrou resultados promissores. As métricas de desempenho indicaram valores consideráveis de precisão e revocação, sugerindo a capacidade do modelo de identificar armas em diversas condições de iluminação e cenários. Os altos valores de revocação indicam que o modelo é capaz de localizar corretamente a maioria das armas presentes nas imagens, enquanto os elevados valores de precisão evidenciam que a maior parte das detecções realizadas é correta. Em comparação a outras versões do YOLO e a modelos baseados em CNN, o YOLOv8 demonstrou competitividade, superando muitos dos modelos anteriores em relação a essas métricas.

VI. CONCLUSÃO

Este estudo apresentou o potencial do YOLOv8 na detecção de armas em ambientes sensíveis à segurança, apresentando resultados promissores de precisão, revocação e rapidez de processamento. A classe “granada” obteve desempenho particularmente alto, possivelmente graças à sua forma mais distinta e à qualidade dos exemplos no conjunto de dados. Ainda assim, desafios permanecem para classes como “rifle” e “pistola”, que alcançaram valores de F1 e *recall* inferiores.

A adoção de uma arquitetura *anchor-free*, aliada a ajustes como o CIoU e DFL, demonstrou benefícios significativos na estabilidade e convergência do modelo, evidenciando que soluções mais recentes de detecção de objetos podem superar arquiteturas anteriores em cenários de aplicação real. No entanto, a pesquisa revela oportunidades de aprimoramento por meio do enriquecimento do conjunto de dados, da aplicação de técnicas de *data augmentation* direcionadas e da análise de explicabilidade, visando identificar os fatores exatos que afetam o desempenho do modelo em classes mais desafiadoras.

Por fim, ainda que a implantação de sistemas de vigilância automatizada traga potenciais ganhos em segurança, cabe aos pesquisadores, desenvolvedores e gestores considerar fatores como privacidade, transparência e governança de dados, assegurando que soluções tecnológicas sejam utilizadas de forma ética e eficiente. Dessa forma, o YOLOv8 mostra-se uma abordagem promissora e equilibrada, mas que, para seu uso em larga escala, deve vir acompanhada de uma avaliação sistemática dos riscos e benefícios, consolidando-se como ferramenta valiosa na redução de ameaças.

REFERÊNCIAS

- [1] J. Garbarino, C. P. Bradshaw, and J. A. Vorrasi, “Mitigating the effects of gun violence on children and youth,” *The Future of children*, 2002.
- [2] S. Narejo, B. Pandey, D. Esenarro Vargas, C. Rodriguez, and M. R. Anjum, “Weapon detection using yolo v3 for smart surveillance system,” *Mathematical Problems in Engineering*, vol. 2021, no. 1, p. 9975700, 2021.
- [3] United Nations, Office on Drugs and Crime, “Global study of homicide,” 2025, accessed: March 24, 2025. [Online]. Available: <https://www.unodc.org/documents/data-and-analysis/gsh/Booklet1.pdf>
- [4] S. Velastin, B. Boghossian, and M. Vicencio-Silva, “A motion-based image processing system for detecting potentially dangerous situations in underground railway stations,” *Transportation Research Part C: Emerging Technologies*, vol. 14, pp. 96–113, 04 2006.
- [5] T. T. Santos, J. G. A. Barbedo, S. Ternes, J. Camargo Neto, L. V. Koenigkan, and K. X. S. d. Souza, “Visão computacional aplicada na agricultura,” *Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas*, pp. 146–164, 2020.
- [6] G. Jocher and U. Team, “Ultralytics yolo11: Cutting-edge object detection,” 2025, accessed: March 24, 2025. [Online]. Available: <https://github.com/ultralytics/ultralytics>
- [7] M. Hussain, “Yolov1 to v8: Unveiling each variant—a comprehensive review of yolo,” *IEEE access*, vol. 12, pp. 42 816–42 833, 2024.
- [8] M. Lima, D. Ferreira, E. Dias, M. Mota, A. Chagas, and P. Lobo, “Computer vision for weapon detection in educational environments: A systematic literature review,” in *Anais Estendidos do XXX Simpósio Brasileiro de Sistemas Multimídia e Web*. Porto Alegre, RS, Brasil: SBC, 2024, pp. 121–128. [Online]. Available: https://sol.sbc.org.br/index.php/webmedia_estendido/article/view/30491
- [9] N. Anand and R. K. Koshariya, “SaveLives - A Real-Time Threat Detection System,” in *2022 1st International Conference on Informatics (ICI)*. Noida, India: IEEE, Apr. 2022, pp. 114–119. [Online]. Available: <https://ieeexplore.ieee.org/document/9786892/>
- [10] S. Ahmed, M. T. Bhatti, M. G. Khan, B. Lövsström, and M. Shahid, “Development and Optimization of Deep Learning Models for Weapon Detection in Surveillance Videos,” *Applied Sciences*, vol. 12, no. 12, p. 5772, Jun. 2022. [Online]. Available: <https://www.mdpi.com/2076-3417/12/12/5772>
- [11] P. Isaac Ritharson, G. Madhavan, M. Rajeswari, and D. Brindha, “Prevention of School Shooting using Neural Networks and Computer Vision,” in *2022 Third International Conference on Intelligent Computing Instrumentation and Control Technologies (ICICICT)*. Kannur, India: IEEE, Aug. 2022, pp. 1703–1709. [Online]. Available: <https://ieeexplore.ieee.org/document/9917656/>
- [12] J. Ruiz-Santaquiteria, A. Velasco-Mata, N. Vallez, O. Deniz, and G. Bueno, “Improving handgun detection through a combination of visual features and body pose-based data,” *Pattern Recognition*, vol. 136, p. 109252, Apr. 2023. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0031320322007312>
- [13] S. M. Keerthana, S. R., and Y. P., “Weapon detection for security using the yolo algorithm with email alert notification,” in *2024 International Conference on Innovations and Challenges in Emerging Technologies (ICICET)*. IEEE, 2024.
- [14] P. Yadav, N. Gupta, and P. K. Sharma, “Robust weapon detection in dark environments using YOLOv7-DarkVision,” *Digital Signal Processing*, vol. 145, p. 104342, Feb. 2024. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S1051200423004372>
- [15] H. Sivakumar, V. Arvind.R, P. R. V, and G. Balamurugan, “Novel Deep Learning Pipeline for Automatic Weapon Detection,” in *2023 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)*. Los Alamitos, CA, USA: IEEE Computer Society, Dec. 2023, pp. 1–5. [Online]. Available: <https://doi.ieeecomputersociety.org/10.1109/CSDE59766.2023.10487762>
- [16] M. P. Rosales, C. Rodriguez, Y. Pomachagua, and C. Navarro, “Firearm Detection in Images of Video Surveillance Cameras with Convolutional Neural Networks,” in *2021 13th International Conference on Computational Intelligence and Communication Networks (CICN)*. Lima, Peru: IEEE, Sep. 2021, pp. 61–65. [Online]. Available: <https://ieeexplore.ieee.org/document/9574690/>

- [17] RHackathon, “Weapon detection dataset,” <https://universe.roboflow.com/rhackathon/weapon-detection-aoxpz>, aug 2023, visited on 2024-07-26. [Online]. Available: <https://universe.roboflow.com/rhackathon/weapon-detection-aoxpz>
- [18] R. T. Magar and N. Shahadat, “Real-time gun detection using yolo: A deep learning approach for public safety,” in *Proceedings of the 27th International Conference on Computer and Information Technology (ICCIT)*. Cox’s Bazar, Bangladesh: IEEE, 2024, pp. 963–967.
- [19] F. A. Warsi, M. Abdullah, M. N. Husen, M. Yahya, S. Khan, and N. Jawaid, “Gun detection system using yolov3,” in *2019 IEEE 6th International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA)*. Kuala Lumpur, Malaysia: IEEE, 2019.
- [20] A. H. Ashraf, M. Imran, A. M. Qahtani, A. Alsufyani, O. Almutiry, A. Mahmood, M. Attique, and M. Habib, “Weapons detection for security and video surveillance using cnn and yolo-v5s,” *Computers, Materials & Continua*, vol. 70, no. 2, pp. 2761–2774, 2022.
- [21] S. Pawar, K. Pandit, and N. N. Chiplunkar, “Fire and gun detection using yolo v3 for surveillance system,” in *International Conference on Artificial Intelligence and Data Engineering (AIDE)*. IEEE, 2022.
- [22] N. N C, “Smart surveillance: Deep learning-based weapon detection using yolo,” *International Research Journal of Innovations in Engineering and Technology*, vol. 12, pp. 2395–0056, 03 2025.
- [23] Python Software Foundation, “Python: Linguagem de programação — versão 3.10.12,” <https://www.python.org/downloads/release/python-31012/>, 2025, linguagem de programação interpretada, utilizada neste trabalho na versão 3.10.12.