

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO
PIAÚICURSO SUPERIOR EM ANÁLISE E DESENVOLVIMENTO DE
SISTEMAS**

CARLOS EDUARDO GUEDES

**REFORÇANDO A SEGURANÇA ESCOLAR: MITIGAÇÃO DE
AMEAÇAS POR MEIO DE VISÃO COMPUTACIONAL**

**CORRENTE – PI
2024**

CARLOS EDUARDO GUEDES

REFORÇANDO A SEGURANÇA ESCOLAR: MITIGAÇÃO DE AMEAÇAS
POR MEIO DE VISÃOCOMPUTACIONAL

Trabalho de Conclusão de Curso submetido ao Instituto Federal de Educação, Ciência e Tecnologia do Piauí - Campus Corrente, como requisito parcial para obtenção do grau de Tecnólogo em Análise e Desenvolvimento de Sistemas.

Linha de Pesquisa: Visão Computacional

Orientador: Prof. Me. Carlos Estevão Bastos Sousa

Coorientador: Prof. Dr. Matheus Emerick de Magalhães

CORRENTE – PI
2024

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Guedes, Carlos Eduardo

G924r Reforçando a segurança escolar: : mitigação de ameaças por meio de
visãocomputacional / Carlos Eduardo Guedes. - 2024.
30 p.: il. color.

Trabalho de Conclusão de Curso (Análise e Desenvolvimento de
Sistemas) - Instituto Federal de Educação, Ciência e Tecnologia do
Piauí, Campus Corrente, 2024.

Orientador : Prof Me. Carlos Estevão Bastos Sousa .

Coorientador : Prof Dr. Matheus Emerick de Magalhães.

1. Análise e Desenvolvimento de Sistemas - estudo e ensino. 2.
Aprendizado de máquina. 3. Ataques a escola. 4. Detecção de
objetos.I. Título.

CDD - 004

Elaborado por Tefischer Huanderson Soares e Sousa CRB 3/1251

AGRADECIMENTOS

Neste momento de culminação acadêmica, não poderia deixar passar sem expressar minha profunda gratidão a todos que contribuíram direta ou indiretamente para a realização deste trabalho, citar o nome de todos os colaboradores deixaria este texto de agradecimento muito extenso, por isso, seguem os agradecimentos especiais.

Gostaria de agradecer primeiramente a Deus por me permitir chegar até aqui e me conceder tal capacidade, por estar sempre me guiando por onde devo seguir.

Aos meus pais Marinete Pereira Guedes e Cerisvaldo de Souza Guedes, pois sempre me apoiaram e contribuíram para meu crescimento intelectual e pessoal como um todo, são o exemplo de pessoa a quem quero seguir.

Ao professor Carlos Estevão, em que sua orientação dedicada e ensinamentos valiosos foram fundamentais para moldar este trabalho, sua paciência, sabedoria e apoio inabalável se tornaram uma fonte de inspiração e motivação ao longo desse jornada.

Aos membros da banca examinadora, agradeço verdadeiramente pelo tempo e esforço dedicado a análise deste trabalho, seus comentários construtivos contribuíram para o aprimoramento deste trabalho.

Aos meus amigos e colegas de curso, agradeço pela companhia, troca de experiências e conhecimentos ao longo desses anos. Suas palavras de estímulo foram imprescindíveis para manter meu foco e determinação até o fim.

Por fim, gostaria de agradecer as fontes de conhecimentos, sejam bases bibliográficas ou acadêmicas que foram o alicerce para a realização deste trabalho.

“O conhecimento é em si mesmo um poder”
(Francis Bacon)

RESUMO

O aumento preocupante de ataques e atentados em escolas tem causado danos irreparáveis e afetado diretamente as famílias e toda a comunidade envolvida. Diante dessa realidade, é proposto o desenvolvimento de uma solução para mitigar esses incidentes, através da implementação de uma *Application Programming Interface* (API) de Visão Computacional. O objetivo é desenvolver e avaliar a eficácia dessa API na detecção de armas de fogo e facas em imagens e vídeos, visando fornecer uma ferramenta eficiente para a segurança escolar. Para alcançar os objetivos, é empregado o *framework* *You Only Look Once* (YOLOv8) para identificação das armas e o *Django Rest Framework* (DRF) para o desenvolvimento da API. A avaliação da eficácia do modelo é realizada por meio de testes *recall*, no qual foram alcançados, 94,8 % para facas e 89,3 % para armas de fogo, e de precisão alcançou-se 90,7 % para armas de fogo e 95,5 % para facas, respectivamente, evidenciando a eficácia do modelo na identificação das classes para as quais foi treinado. Diante dos resultados apresentados, pode-se afirmar que esta pesquisa representa um avanço significativo para a segurança escolar, oferecendo uma ferramenta precisa e eficiente para a detecção precoce de ameaças, com potencial para salvar vidas e proteger comunidades escolares.

Palavras-chaves: Aprendizado profundo, Ataques às escolas, Detecção de objetos, Visão Computacional, YOLOv8.

ABSTRACT

The worrying increase in attacks and attacks on schools has caused irreparable damage and directly affected families and the entire community involved. Given this reality, It is proposed to develop a solution to mitigate these incidents, through implementation of a Computer Vision Application Programming Interface (API). The objective is to develop and evaluate the effectiveness of this API in detecting firearms and knives in images and videos, aiming to provide an efficient tool for school security. To achieve the objectives, the You Only Look Once (YOLOv8) framework is used for weapon identification and the Django Rest Framework (DRF) for development of the API. The evaluation of the effectiveness of the model is carried out through recall tests, in which were achieved, 94.8 % for knives and 89.3 % for firearms, and accuracy was achieved 90.7 % for firearms and 95.5 % for knives, respectively, demonstrating the effectiveness of the model in identifying the classes for which it was trained. Given the results presented, it can be said that this research represents a significant advance for the school security, offering an accurate and efficient tool for early detection of threats, with the potential to save lives and protect school communities

Keywords: Deep Learning, School Attacks, Object Detection, Computer Vision, YOLOv8.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de detecção do modelo.	19
Figura 2 – Procedimentos metodológicos realizados para elaboração da API.	23
Figura 3 – Exemplo de dados para treinar o modelo.	24
Figura 4 – Curvas de confiança <i>recall</i> e confiança F1	28
Figura 5 – Curvas de precisão- <i>recall</i> e precisão-confiança	29
Figura 6 – Amostra de resultados.	30
Figura 7 – Detecção de ataque em Columbine.	31

LISTA DE TABELAS

Tabela 1 – Tipos de armas utilizadas nos ataques em escolas.....	10
Tabela 2 – Comparação com os trabalhos relacionados.....	17
Tabela 3 – Exemplo Matriz de Confusão.	20
Tabela 4 – Matriz de Confusão.....	27

LISTA DE ABREVIATURAS E SIGLAS

API	Application Programming Interface
REST	Representational State Transfer
YOLO	You Only Live Once

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Objetivos	11
1.1.1	Objetivo geral	11
1.1.2	Objetivos específicos	11
1.2	Estrutura do Trabalho	12
2	JUSTIFICATIVA	13
3	FUNDAMENTAÇÃO TEÓRICA.....	16
3.1	Trabalhos relacionados	16
3.2	Tecnologias utilizadas.....	18
3.2.1	Visão Computacional	18
3.2.2	Detecção de objetos	19
3.2.3	YOLO.....	20
3.2.4	Django e Django REST <i>framework</i>	20
3.3	Métricas de Avaliação	20
4	PROCEDIMENTOS METODOLÓGICOS.....	23
4.1	Instrumentos de coleta de dados.....	24
4.2	Pré-processamento dos dados	25
4.3	Utilização do <i>Framework</i> YOLO	25
5	RESULTADOS E DISCUSSÕES	27
6	CONCLUSÕES E SUGESTÕES DE TRABALHOS FUTUROS.....	32
	REFERÊNCIAS.....	33

1. INTRODUÇÃO

Nos últimos anos, o relato de incidentes de violência armada nas escolas têm se repetido cada vez mais, o Instituto Sou da Paz (2023) revelou, em seu estudo, um aumento significativo nos ataques terroristas em escolas ao longo dos últimos 21 anos, refletindo em um aumento alarmante no número de vítimas fatais e não fatais. Até a data do levantamento, em 22 de maio de 2023, foram registrados 24 casos no total, resultando em 137 vítimas, das quais 45 foram fatais e 92 não fatais. Como evidenciado na Tabela 1, a maioria desses ataques envolveu o uso de armas de fogo e armas brancas, totalizando 11 e 10 casos, respectivamente.

Tabela 1 – Tipos de armas utilizadas nos ataques em escolas.

Arma principal utilizada	Casos	Nº vítimas fatais	Vítimas fatais (%)
Arma de fogo	11	34	76%
Arma branca	10	11	24%
Total	21	45	100%

Fonte: Instituto Sou da Paz (2023).

Na Tabela 1 são exibidos dados quantitativos acerca dos ataques em escolas nos últimos 21 anos. Desses, segundo o estudo, 46 % foram com armas de fogo, 42 % com armas brancas e os demais ocorreram com outros meios, como por exemplo armas de pressão, balestra e explosivos, que somam 12 % do total de casos. No que tange a vítimas fatais, houveram 34, o que corresponde a 76 % envolvendo o uso de armas de fogo. Em relação a armas brancas, houveram 11 vítimas, correspondendo a 24 %. Ademais não houveram vítimas.

No estudo é informado ainda que, no primeiro quadrimestre de 2022 foram registrados cinco casos, três deles na mesma semana de abril. Outro fator importante é que dois dos três ataques com maior número de vítimas ocorreram entre 2019 e 2022, evidenciando assim um recente aumento dos casos.

No trabalho de Madfis (2016) é abordado o medo dos profissionais que atuam em escolas em relação aos ataques em massa nesses ambientes e sua conexão com a crescente criminalização das escolas públicas nos Estados Unidos. O autor realizou entrevistas com diversos profissionais escolares, incluindo administradores, conselheiros, oficiais de segurança, policiais e professores, com o objetivo de compreender suas percepções e justificativas para a expansão da disciplina punitiva e do aumento da segurança nas escolas. Além disso, para ilustrar a gravidade desses eventos, o autor apresenta casos de ataques em escolas, como o massacre de Columbine em 1999, que foi discutido anteriormente em outro trabalho.

Nesses casos, a localização rápida e eficiente do autor do crime é crucial para permitir uma resposta rápida e apropriada das autoridades de segurança. A demora na identificação do autor pode resultar em atrasos na implementação de medidas preventivas e na adoção de ações necessárias pelos vigilantes ou responsáveis, o que pode potencialmente aumentar o risco para os alunos e funcionários de instituições escolares e outros órgãos.

Com base nessas análises, neste trabalho é proposto o desenvolvimento de uma *Application Programming Interface* (API) baseada em Visão Computacional para detectar armas de fogo e facas. É importante destacar que o foco desta aplicação é a segurança escolar, embora sua utilização não esteja restrita apenas a esse ambiente. Este estudo destaca-se pelas seguintes contribuições:

- a) Auxílio na detecção de armas de fogo e armas brancas em ambientes escolares;
- b) Possibilitar a análise contínua e automática das imagens da câmeras;
- c) Contribuir para a que se possa proporcionar um ambiente escolar mais seguro;

1.1 Objetivos

Partindo das abordagens anteriores, foi listada uma série de objetivos que se busca alcançar com este trabalho. Esses são apresentados a seguir.

1.1.1 Objetivo geral

O objetivo central deste estudo é contribuir na detecção de armas como facas e armas de fogo através de uma API baseada em Visão Computacional, com a capacidade de identificar facas e armas de fogo em vídeos provenientes de câmeras de segurança. Essa iniciativa visa reduzir os impactos causados por ataques em escolas e em outros setores.

1.1.2 Objetivos específicos

- Realizar uma revisão de literatura para identificar estudos relevantes sobre o aumento de ataques e atentados em escolas, assim como técnicas de Visão Computacional aplicáveis à detecção de armas de fogo e facas.
- Selecionar uma técnica de Visão Computacional compatível com os objetivos do estudo, considerando sua eficácia na detecção precisa de armas de fogo e facas em imagens e vídeos de câmeras de segurança.
- Encontrar e utilizar uma base de dados qualificada e representativa, contendo imagens e vídeos que permitam o treinamento e validação do modelo de detecção de armas.
- Desenvolver e implementar algoritmos de detecção capazes de identificar com precisão armas de fogo e facas em vídeos de câmeras de segurança, utilizando a técnica escolhida de Visão Computacional.
- Avaliar a eficácia da API desenvolvida na detecção de armas de fogo e facas, utilizando métricas como acurácia e recall, para verificar sua capacidade de identificar corretamente as classes para as quais foi treinada.
- Implementar a API utilizando o *framework* *You Only Live Once* (YOLOv8) para a detecção de armas e o Django *REST Framework* para o desenvolvimento da interface de programação de aplicativos.

1.2 Estrutura do Trabalho

Este trabalho está estruturado em seis capítulos distintos. Neste Capítulo, denominado como Introdução, são abordadas informações sobre os ataques em ambientes escolares. No segundo Capítulo, Justificativa, são explorados os principais fatores que motivaram a realização deste estudo. No terceiro Capítulo, Fundamentação Teórica, são discutidos os trabalhos que serviram como base para a elaboração deste projeto. No quarto Capítulo, intitulado Procedimentos Metodológicos, são detalhadas todas as etapas, desde o treinamento do modelo YOLO até a construção da API. Em seguida, no quinto Capítulo, são apresentados os Resultados e Discussões, onde é abordado a eficácia do modelo desenvolvido. Por último, no sexto Capítulo, são apresentadas as conclusões e as sugestões para futuras pesquisas.

2. Justificativa

Em um contexto sociopolítico contemporâneo permeado pela escalada da violência, o ambiente escolar emerge como um espaço suscetível à manifestação de temores relacionados à violência armada. Incidentes de disparos de arma de fogo em corredores escolares alteram substancialmente a percepção do local como um ambiente propício ao aprendizado, tornando-o, em vez disso, um cenário de ansiedade e medo.

No estudo conduzido por Böckler et al. (2018) é abordada a comparação entre os perfis de desenvolvimento de indivíduos envolvidos em ataques escolares e aqueles associados a ataques terroristas Jihadi na Alemanha. A pesquisa envolveu uma análise qualitativa de processos judiciais, examinando os casos de sete perpetradores de ataques em escolas, com idades entre 13 e 23 anos, e sete perpetradores de ataques Jihadi, com idades entre 21 e 28 anos.

No estudo, são mencionados casos de ataques terroristas, incluindo o incidente envolvendo Pekka-Eric Auvinen, que perpetrara um ataque em uma escola em Jokela, Finlândia, em 2007, resultando na morte de oito pessoas antes de cometer suicídio. Antes do ataque, Auvinen havia elaborado um portfólio de mídia revelando um profundo interesse pela violência, além de motivações subjacentes ao ato. Outro exemplo citado é o ataque em Oslo/Utøya, Noruega, em 2011, perpetrado por Anders Behring Breivik, motivado por questões religiosas, resultando em um trágico massacre.

Em outra pesquisa, conduzida pelo autor Erlandsson e Meloy (2018), é apresentado um relatório de caso referente ao ataque à escola de Trollhättan, na Suécia. No incidente, o perpetrador utilizou uma espada para atacar alunos e professores. O estudo aborda a história do agressor, investigando a relação entre suas ideologias e os motivos subjacentes ao ataque, os quais incluem a perda do emprego.

Ainda em relação ao trabalho, também é abordada uma série de ataques em escolas nos Estados Unidos, destacando eventos como o tiroteio na Escola de Columbine em 1999, o massacre na Escola de Sandy Hook em 2012 e o tiroteio na Marjory Stoneman Douglas High School em 2018. Tais incidentes resultaram em um grande número de vítimas fatais e deixaram um profundo trauma nos sobreviventes. Além disso, foram mencionados casos na Europa, como o ataque à Escola de Winnenden, na Alemanha, em 2009, no qual um ex-aluno tirou a vida de 15 pessoas antes de cometer suicídio. Outro caso na Finlândia, em 2007, envolveu um estudante que realizou disparos em sua escola, resultando em 8 vítimas fatais. Adicionalmente, foi citado um incidente ocorrido na França em 2012, no qual um ataque armado em uma escola judaica em Toulouse resultou na morte de 4 pessoas, incluindo 3 crianças.

O estudo conduzido por Sandberg et al. (2014) é concentrado na análise das influências culturais dos tiroteios em escolas, incluindo os ataques terroristas ocorridos na Noruega em 2011. Além disso, os autores abordam outros casos notáveis, como o ocorrido na Universidade Politécnica Virginia Tech, nos Estados Unidos, em 2007. Nesse incidente, um estudante chamado Seung-Hui Cho tirou a vida de 32 pessoas e feriu outras 17 antes de cometer suicídio, sendo um dos tiroteios em massa mais letais da história dos Estados Unidos.

No artigo ainda é relatado mais dois ataques na Alemanha, o Massacre de Erfurt acontecido em 26 de abril de 2002 na escola Gutenberg-Gymnasium, em Erfurt, em que um ex-aluno chamado Robert Steinhäuser, de 19 anos, adentrou armado em uma escola e matou 12 professores, duas alunas e um policial antes de cometer suicídio. O segundo ataque mencionado também ocorrido na Alemanha foi o massacre de Winnenden, ocorrido em 11 de março de 2009 em Winnenden e Wendlingen, no sul da Alemanha, onde Tim Kretschmer, um ex-aluno de 17 anos, entrou em sua antiga escola e matou 15 pessoas, 9 alunos, três professores antes de fugir e cometer suicídio.

Baseando-se na análise crítica de fenômenos de violência escolar e terrorismo, o estudo de Cattapan (2020) que tem como título, "*A Critical Analysis of the Phenomena of Bullying and Terrorism*", apresenta análises acerca das causas de tais ataques, assim como cita incidentes trágicos como o Massacre de Realengo que ocorreu em uma escola no Rio de Janeiro no ano de 2011. Nesse incidente um indivíduo invadiu uma escola e iniciou um ataque armado, resultando na perda de várias vidas de estudantes e profissionais da educação. Esse incidente levantou questões sobre medidas preventivas a serem adotadas.

Abordando eventos no estado do Piauí, em uma reportagem do canal Cidade Verde (2023) é destacada a proposta do governador de implementar um plano de evacuação para escolas em casos de ataques. Essa medida foi sugerida após um ex-aluno de 17 anos adentrar a Unidade Escolar Helvídio Nunes, armado com uma faca, e invadir uma sala de aula para ameaçar alunos. Graças à intervenção de uma professora, que negociou com o agressor para que ele se recolhesse em um banheiro enquanto as autoridades eram acionadas, a situação foi controlada.

Em uma matéria do Portal o Dia (2023) é revelado que, após o trágico ataque ocorrido em uma creche na cidade de Blumenau (SC), o Piauí registrou 12 ocorrências, no qual 4 crianças perderam a vida. Oito desses incidentes foram documentados nos municípios de Bom Princípio, Picos, Matias Olímpio e Buriti dos Lopes.

Considerando as informações apresentadas, é inegável que a aplicação da Visão Computacional oferece perspectivas promissoras para aprimorar a segurança nas escolas. Ao realizar análises em tempo real de imagens e vídeos, essa tecnologia permite a utilização de algoritmos especializados na detecção de objetos e na identificação de potenciais ameaças, como armas. Dessa forma, a Visão Computacional desempenha um papel crucial na proteção não apenas dos alunos, mas também dos professores e funcionários, contra a violência armada. Ao possibilitar uma detecção precoce de situações de risco, ela contribui significativamente para o fortalecimento das medidas de segurança já existentes, garantindo um ambiente escolar mais seguro e protegido.

No capítulo a seguir, será apresentada a Fundamentação Teórica, na qual serão discutidos os estudos que serviram de embasamento para o desenvolvimento do trabalho proposto.

3. FUNDAMENTAÇÃO TEÓRICA

A base teórica deste trabalho foi construída a partir de uma extensa revisão teórica que forneceu o alicerce para compreender o contexto explorado neste estudo. Segue uma breve apresentação a respeito dos principais trabalhos relacionados.

3.1 TRABALHOS RELACIONADOS

Na área de Visão Computacional é essencial investigar o desempenho dos algoritmos de detecção de objetos para a identificação de múltiplas pessoas. Um estudo relevante nesse contexto é o trabalho de Vasantha et al. (2023), intitulado "*Performance Analysis of Object Detection Algorithms for Multi-Person Identification*", no estudo os autores fizeram análises de *Histogram of Oriented Gradients* (HOG) - *Support Vector Machine* (SVM), YOLOv8 e RetinaNet, implementando-os e avaliando seu desempenho de forma abrangente. Os resultados obtidos foram de 0,97 de *Recall* quando usado o HOG-SVM, 0,94 com o YOLO e 1,0 com o RetinaNet. Esses resultados evidenciam a capacidade desses algoritmos em realizar a contagem de pessoas de maneira precisa.

No mesmo trabalho, os autores exploram as dificuldades enfrentadas, como oclusões, distribuições desiguais de densidade e diferenças de escala e perspectiva. Os algoritmos HOG-SVM, YOLOv8 e RetinaNet foram avaliados quanto à sua capacidade de lidar com esses desafios. A partir dos resultados os autores evidenciam que todos os três algoritmos tiveram bom desempenho na detecção e contagem de pessoas, com o algoritmo RetinaNet alcançando o melhor resultado, com *Recall* de 1,0.

Al-obidi e Kacmaz (2023), no trabalho "*Facial Features Recognition Based on their Shape and Color using YOLOv8*", é apresentado que o rosto humano possui vários aspectos que é uma fonte rica de informações, com características distintas, como olhos, nariz e boca, oferecendo uma riqueza de dados. O reconhecimento dessas características é o que diferencia as pessoas umas das outras. A técnica utilizada possui várias aplicações práticas, desde o desbloqueio de *smartphones* até o reforço da segurança em espaços públicos.

Neste contexto, os autores propõem um novo conjunto de dados criado especificamente para o reconhecimento de características faciais com base em sua forma e cor, utilizando o modelo de detecção de objetos YOLOv8. O conjunto de dados final contém mais de 2.000 imagens com anotações de seis classes diferentes, como olho azul, olho castanho, nariz arredondado, sobrancelhas arredondadas, nariz pontudo e sobrancelhas retas. Os resultados do experimento mostram que a versão leve do YOLOv8 obteve um desempenho considerável, alcançando uma média de precisão média (mAP) de 91,3 % no conjunto de dados proposto.

No trabalho também é mencionado que, desde 1999 várias técnicas foram propostas para o reconhecimento facial, entre elas o uso de classificadores como o *Nearest Feature Line* (NFL) e o método proposto por Viola e Jones para identificação rápida e precisa de faces em imagens. Também são mencionados métodos mais recentes, como o uso de classificador *Naive Bayes* e técnicas automáticas baseadas em informações de profundidade. Além disso, destaca-se o papel das *Convolutional Neural Networks* (CNN) no reconhecimento de características faciais e na detecção de objetos em geral. Esses avanços na área têm permitido a aplicação da tecnologia de reconhecimento facial em diferentes contextos, como segurança e autenticação de dispositivos.

No trabalho de Deshpande et al. (2023), intitulado como "*Next-Gen Security: YOLOv8 for Real-Time Weapon Detection*", os autores investigaram o uso do modelo YOLOv8-*Small* para a detecção precisa de armas em situações de tiroteios em massa e crimes violentos. No estudo é destacado a adaptação do modelo em terrenos e condições em diversas condições desafiadoras e enfatizada a eficiência e adaptabilidade do modelo YOLOv8-*Small* na detecção de armas em tempo real. O modelo se mostrou competente na identificação precisa de uma ampla variedade de armas atingindo uma taxa de detecção de 48,6 % mAP, que representa a média de precisão média do modelo para todas as classes, uma confiança de pelo menos 50 % e uma velocidade média de 25 quadros por segundo, validando sua aplicabilidade em operações militares. Além disso, sua adaptabilidade a diferentes condições ambientais garante um desempenho consistente em terrenos desafiadores. Essas conclusões oferecem orientações importantes para melhorar a segurança e eficácia das operações militares.

Na Tabela 2 é apresentada uma análise acerca das especificações dos trabalhos relacionados mencionados e a presente proposta de trabalho.

Tabela 2 – Comparação com os trabalhos relacionados

Trabalho	Algoritmo(s)	Recall	Nº de Classes	Contexto
Vasantha et al.	HOG-SVM YOLOv8 RetinaNet	97 % 94 % 100 %	-	Detecção e contagem de múltiplas pessoas
Al-obidi e Kacmaz	YOLOv8	91,3%	6	Reconhecimento de características faciais
Trabalho Proposto	YOLOv8	89,3 %, 94,8 %	2	Detecção de armas em escolas

De acordo com as informações apresentadas na Tabela 2 pode-se observar que, em todos os trabalhos o YOLO foi utilizado e que no presente trabalho o modelo alcançou um recall de 89,3 % para a classe *gun* e 94,8 % para a classe *knife*, além deste trabalho ser direcionado ao contexto escolar, sendo esse o principal diferencial.

3.2 TECNOLOGIAS UTILIZADAS

Para a execução deste trabalho, utilizaram-se diversas tecnologias, incluindo o YOLOv8 para criar o modelo de detecção de objetos. A linguagem escolhida para implementação foi Python, amplamente reconhecida pela sua aplicação em Inteligência Artificial. Além disso, foi adotado o *Django REST Framework*, que utiliza a linguagem Python para construir APIs com o estilo arquitetural *Representational State Transfer* (REST). Conforme documentado por Gupta (2024), essa abordagem se baseia no protocolo *Hypertext Transfer Protocol* (HTTP) e utiliza métodos como *GET*, *POST*, *PUT* e *DELETE* para manipular recursos de forma eficiente.

3.2.1 VISÃO COMPUTACIONAL,

Como abordado por Marengoni e Stringhini (2009), a Visão Computacional pode ser definida como, uma forma de emular a visão humana, recebendo imagens como entrada e como saída será fornecida uma interpretação da imagem, extraindo características e informações relevantes para a finalidade para que foi desenvolvida.

A Visão Computacional origina-se durante as décadas de 1960 e 1970 quando os pesquisadores da época começaram a explorar a ideia de tentar ensinar os computadores a enxergar como os humanos. No entanto, somente na década de 1980 que houveram avanços significativos na área devido ao desenvolvimento de modelos matemáticos mais sofisticados e a aplicação de técnicas de processamento de imagens. Teóricos como Marr (1982) fizeram propostas de abordagens para a visão como um processos de inferência baseado em diferentes níveis de representação.

Na década de 1990, houve um grande impulso na área de Visão Computacional devido ao aumento do poder de processamento computacional e o acesso a conjuntos de dados ricos em termos visuais. Nesse mesmo período, houve a descoberta de técnicas mais avançadas de processamento de imagens como a segmentação de imagem e filtragem linear. Na década de 2000, técnicas como redes neurais artificiais começaram a surgir, proporcionando outro grande salto na área. Algoritmos de aprendizado profundo permitiram a extração de recursos de forma automática em imagens, assim o reconhecimento de objetos complexos com alta precisão se tornou possível.

Algumas aplicações práticas da Visão Computacional envolvem projetos como detecção de objetos, avaliação da qualidade de produtos, contagem e detecção de pessoas, detecção de expressões faciais de pessoas, entre outros.

3.2.2 Detecção de objetos

A evolução da detecção de objetos na Visão Computacional tem sido significativa ao longo das últimas décadas, enfrentando desafios fundamentais. Desde os primeiros algoritmos até o estado da arte atual, a busca por identificar e localizar objetos em imagens ou vídeos tem sido uma área de estudo em constante progresso. Os algoritmos iniciais já faziam uso de técnicas como as *bounding boxes* para delimitar áreas de interesse, marcando o início desse campo e estabelecendo as bases para o desenvolvimento de técnicas mais sofisticadas. A partir da Figura 1 pode-se observar um exemplo de *bounding box*, representada pela figura geométrica vermelha.

Figura 1 – Exemplo de detecção do modelo.



Fonte: Adaptado de Pixabay (2023).

A partir da Figura 1, é possível observar um soldado empunhando uma arma de fogo, com a bounding box destacando a detecção realizada pelo modelo. A classe dessa detecção é identificada como "gun", que, traduzido do inglês para o português brasileiro, significa pistola. Além disso, a precisão dessa detecção é indicada como 78 %, ressaltando que essa imagem não faz parte do conjunto de treinamento.

No artigo de Zou et al. (2023), por exemplo, é contextualizada a evolução da detecção de objetos e destacada a importância dessa área no âmbito da Visão Computacional. A emergência de técnicas como Keras e YOLO reflete esse avanço. Atualmente, o Keras, reconhecido por apresentar métricas impressionantes, é robusto em suas capacidades de detecção, porém, enfrenta desafios quando se trata de processamento em tempo real. Isso pode ser um obstáculo em cenários como vigilância escolar, onde recursos de hardware podem ser limitados. Já o YOLO, além de oferecer boas métricas, demonstra um tempo de resposta mais ágil em comparação com o Keras, tornando-se uma opção mais viável para aplicações que demandam processamento rápido, como a vigilância em tempo real.

3.2.3 YOLO

O YOLO, segundo Ultralytics (2024), é um *framework* de Visão Computacional conhecido por sua capacidade de realizar detecção de objetos e segmentação em tempo real, oferecendo bons resultados de desempenho em termos de velocidade e precisão.

Na data da redação deste trabalho, a versão mais recente do YOLO é a 9, lançada recentemente, e promete oferecer melhorias substanciais e maior completude. No entanto, para este estudo, optou-se por utilizar a versão 8, uma vez que, no início do desenvolvimento, a versão mais recente ainda não estava disponível.

3.2.4 Django e Django REST framework

Segundo Django Software Foundation (2023), o Django é um *framework web FullStack* de código aberto, baseado em Python, projetado para simplificar questões comuns como rotas e autenticação. Já o Django REST *framework*, de acordo com MkDocs (2022), é uma biblioteca que facilita a criação de APIs REST utilizando a estrutura do Django.

3.3 MÉTRICAS DE AVALIAÇÃO

Ao lidar com Aprendizado de Máquina, torna-se essencial que os modelos tenham a capacidade de realizar previsões precisas em conjuntos de dados não analisados previamente, uma vez que, em uma aplicação real o modelo não vai lidar com um conjunto que foi treinado. Para uma avaliação acerca da eficácia do modelo, são consideradas várias técnicas, como por exemplo a matriz de confusão, que apresenta as previsões realizadas pelo modelo e os valores reais, nesta existem os Verdadeiros Positivos, Falsos Negativos, Falso Positivos e Falsos Negativos, conforme é apresentado na Tabela 3.

Tabela 3 – Exemplo Matriz de Confusão.

		Predições	
		Sim	Não
Real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Autor (2024).

No exemplo apresentado, existem valores indicados como Verdadeiro Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN). Os Verdadeiros Positivos (VP) representam as detecções verdadeiras feitas pelo modelo e que seu valor real também é verdadeiro. Falso Negativo (FN) representa situações em que o modelo prevê erroneamente algo como sendo falso mas seu valor real é verdadeiro. Falso Positivo (FP) diz respeito às previsões verdadeiras em que o valor real é falso. Verdadeiro Negativo (VN) acontece quando o modelo prevê algo como falso e a previsão condiz com o valor real. Além da matriz de confusão, existem outras métricas que são analisadas, como a precisão, acurácia, *Recall* e *F1-score*, que serão apresentadas a seguir.

Como mencionado, além da matriz de confusão, existem outras formas de analisar um modelo de aprendizado de máquina. A acurácia é uma métrica bem simples que apresenta o índice de classificação correta com base na quantidade total de amostras. Essa métrica, porém, apresenta um problema: em uma base de dados desbalanceada, uma acurácia alta pode representar uma alta taxa de acerto em uma classe com mais amostras, em contrapartida, uma classe com menor quantidade de amostras pode apresentar uma grande quantidade de erros. Por esse motivo, nem sempre o uso da acurácia como métrica de avaliação irá garantir a escolha do melhor modelo. A métrica é dada pela Equação 3.1.

$$acc = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.1)$$

A precisão dada pela Equação 3.2, realiza uma proporção entre as das instâncias verdadeiramente positivas e o total de detecções positivas feitas pelo modelo, ou seja, é uma análise da capacidade do modelo de identificar um determinado objeto de forma correta.

$$prec = \frac{VP}{VP + FP} \quad (3.2)$$

Recall, também conhecido como sensibilidade, apresentado na Equação 3.3, é a proporção das detecções verdadeiramente positivas de uma determinada classe e o total de elementos dessa classe. Para o trabalho proposto, esta avaliação se torna bem relevante, uma vez que a prioridade é a identificação dos verdadeiros positivos.

$$rec = \frac{VP}{VP + FN} \quad (3.3)$$

O *F1-score*, obtido pela Equação 3.4, é uma métrica de avaliação que combina precisão e *recall* em uma média harmônica. Essa abordagem visa fornecer um resultado que leve em consideração ambos os aspectos, uma vez que uma avaliação separada entre as duas métricas pode não ser eficaz, especialmente porque o *F1-score* é particularmente sensível ao valor mais baixo entre as duas métricas. Isso destaca a importância de alcançar um equilíbrio entre precisão e *recall* para uma avaliação mais abrangente.

$$f1 = 2 * \frac{prec + rec}{prec + rec} \quad (3.4)$$

Além disso, as curvas de confiança são uma ferramenta importante em Aprendizado de Máquina para avaliar a confiabilidade das previsões feitas pelo modelo. Essas curvas representam graficamente a relação entre uma métrica de desempenho do modelo, como precisão ou *recall* e o nível de confiança associado a essas previsões. O nível de confiança indica o quão certo o modelo está de que uma determinada previsão é correta. Geralmente, as curvas de confiança são construídas plotando-se a métrica de desempenho em relação a diferentes valores de confiança. Isso permite aos desenvolvedores e analistas entender como o desempenho do modelo varia conforme a confiança das previsões aumenta ou diminui.


Na plotagem da curva de confiança de *recall-confidence*, uma curva que se aproxima mais da borda superior direita do gráfico é considerada melhor. Isso significa que o modelo está produzindo altos níveis de *recall* para uma ampla gama de valores de confiança. Idealmente, é buscado um modelo que tenha um alto *recall* mesmo para previsões com alta confiança, indicando que o modelo está identificando a maioria dos exemplos positivos com uma alta taxa de certeza. Por outro lado, uma curva que se aproxima da borda inferior esquerda do gráfico indica um desempenho inferior. Isso significa que o modelo pode estar perdendo muitos exemplos positivos, mesmo para previsões com alta confiança, o que sugere que o modelo não está identificando corretamente os exemplos positivos. Em resumo, uma curva que se aproxima da borda superior direita indica um bom desempenho do modelo, enquanto uma curva que se aproxima da borda inferior esquerda indica um desempenho ruim.

A seguir, no Capítulo 4, intitulado Procedimentos Metodológicos, serão detalhadas as etapas envolvidas na implementação do modelo proposto. Ao final desse, espera-se obter uma compreensão clara e completa das etapas realizadas para a concretização do modelo proposto, preparando o terreno para as discussões e resultados apresentados nos capítulos subsequentes.

4. PROCEDIMENTOS METODOLÓGICOS

Neste capítulo, é detalhada a metodologia empregada na utilização do YOLOv8 para a detecção de armas em ambientes escolares. Serão abordados desde a preparação dos dados até a configuração e ajustes do modelo, destacando os procedimentos de treinamento, validação para assegurar a precisão, acurácia, sensibilidade e demais métricas mencionadas no capítulo anterior. Na Figura 2, são apresentadas as etapas do desenvolvimento da proposta do trabalho.

Figura 2 – Procedimentos metodológicos realizados para elaboração da API.



Fonte: Autor (2024).

Conforme ilustrado na Figura 2, os procedimentos metodológicos compreendem quatro etapas essenciais para a elaboração da API. Inicialmente, conforme detalhado na Subfigura A, ocorre a busca por imagens destinadas ao treinamento do modelo. Essa busca é realizada em bases de dados, que constituem repositórios de grande volume de dados utilizados para o desenvolvimento de Inteligência Artificial. Na Subfigura B, o modelo é submetido ao processo de treinamento.


Nesta fase, o *framework* analisa as imagens extraídas da base de dados, juntamente com as anotações correspondentes, que consistem nas coordenadas indicativas da localização das armas nas imagens do conjunto de treinamento. Essa abordagem permite que o modelo adquira o conhecimento necessário para identificar pistolas e facas. A etapa subsequente é a avaliação da eficácia, conforme delineado na Subfigura C, durante a qual se verifica se o modelo apresentou um desempenho satisfatório após a validação pós-treinamento. Por fim, na Subfigura D, ocorre a implementação da API. Este estágio representa o desenvolvimento propriamente dito, permitindo que outros desenvolvedores possam testá-la e, potencialmente, integrá-la em sistemas mais amplos.

4.1 INSTRUMENTOS DE COLETA DE DADOS

Após uma busca realizada em diversas bases por dados para o treinamento do modelo, é obtido um conjunto de dados disponível em Roboflow (2023), que disponibiliza os dados e anotações a respeito dos dados para o treinamento do modelo. O conjunto de dados possui um total de 9.918 imagens, incluindo imagens de treinamento, validação e testes.

Na Figura 3 é apresentado um exemplo de imagem, em que esta foi usada no treinamento do modelo de Visão Computacional.

Figura 3 – Exemplo de dados para treinar o modelo.



Fonte: Adaptado de Roboflow (2023).

Na Figura 3 é apresentada um exemplar do conjunto de dados usado no treinamento. Essa é dividida em três partes conforme está disposta. Na Subfigura A é exibida anotações acerca da localização da *bounding box* na imagem, isto é, a anotação. Na Subfigura B é apresentado um exemplo de uma imagem sem o processamento e, na Subfigura C, é apresentada a mesma imagem mas com o processamento da anotação, citada na Subfigura A.

É relevante salientar que no conjunto de imagens utilizado, as classes são designadas como *gun* (arma de fogo), *knife* (facas) e *background* (plano de fundo), representando, respectivamente, as categorias de objetos identificados. Daqui em diante, empregaremos os termos conforme a nomenclatura adotada no referido conjunto de imagens.

4.2 Pré-processamento dos dados

Após a coleta de dados, inicia-se o processo de pré-processamento, que envolve principalmente o redimensionamento das imagens para a proporção de 640x640 *pixels*. Em seguida, os dados são divididos em conjuntos de treinamento, validação e teste, correspondendo a 80%, 10% e 10% do conjunto total de dados, respectivamente.

4.3 Utilização do *Framework* YOLO

Após realizar uma revisão bibliográfica a respeito dos principais *frameworks* de Visão Computacional, o YOLO, em sua versão 8, foi o que mais se destacou devido a sua capacidade de lidar com detecção de objetos em tempo real, trazendo um equilíbrio entre desempenho e análise de imagens em tempo real.

O modelo é treinado ao longo de 500 épocas, com um critério de paciência de 50. Isso significa que, caso não haja melhorias no desempenho após esse período, o treinamento será interrompido. Além disso, um lote de 8% das imagens do conjunto de dados é utilizado em cada época.

O treinamento se baseia em imagens e anotações adquiridas da base de dados Roboflow (2023), um conjunto de dados anotado. Essas anotações fornecem informações sobre a localização dos objetos nas imagens.

Para avaliar o modelo, são analisados os resultados em relação à validação por meio de matriz de confusão, acurácia, precisão, *Recall* e *F1-score*.

Adicionalmente, são conduzidos testes de validação complementares, os quais envolvem análises visuais. Utilizados vídeos públicos que contêm armas e imagens provenientes de reportagens sobre ataques reais em escolas para verificar a precisão do modelo na identificação de armas. Essa abordagem é crucial para assegurar que os resultados dos testes visuais estejam alinhados com as métricas de desempenho citadas.

Após treinar e validar o modelo iniciou-se a fase de implementação do modelo em uma API. É dito no trabalho de Fielding (2000) que uma API é um conjunto de regras e protocolos que permitem a comunicação e interação entre diferentes softwares. Permitem e definem as formas que componentes de software e os dados podem ser transmitidos e manipulados.

A escolha do *framework* Django *Representational State Transfer* (REST), para a API proposta foi motivada por utilizar a linguagem de programação Python, uma vez que o YOLO, pertencente a Ultralytics (2024), utilizado neste projeto está adaptado para esta linguagem, assim permitindo uma integração mais fácil e eficiente entre o modelo e demais funcionalidades da API.

A API possui duas rotas distintas. Uma delas destina-se ao cadastro de um novo modelo, sendo útil para atualizações. A segunda rota permite o uso do modelo para detecções manuais ou para os usuários que irão consumi-lo.

No Capítulo 5, intitulado "Resultados e Discussões", serão apresentados de forma detalhada os resultados retornados pelo modelo, incluindo suas métricas de desempenho, bem como alguns resultados de análises visuais.

5. RESULTADOS E DISCUSSÕES

Neste capítulo, destacamos os resultados obtidos após o treinamento e teste do modelo de Visão Computacional, utilizando o conjunto de dados proveniente de Roboflow (2023) e considerando as três classes: Gun, Knife e Background. Na Tabela 4 é exibida a matriz de confusão, fornecendo uma dos resultados alcançados pelo modelo em relação à classificação das imagens.

Tabela 4 – Matriz de Confusão.


		Predições		
		Gun	Knife	Background
Real	Gun	1.158	3	135
	Knife	-	1.189	65
	Background	118	53	-

Fonte: Autor (2024).

Na Tabela 4, são apresentados os resultados da análise de detecção do modelo durante a etapa de teste. Observa-se que o modelo realizou 1.158 detecções corretas de *gun* e 1.189 detecções corretas de *knife*. No entanto, é importante notar que houve 100% de erro na classificação de *background*. É relevante ressaltar que, para este trabalho, o principal foco está nos falsos negativos, ou seja, na não detecção de armas onde estas estão presentes

A análise das curvas de confiança é uma etapa essencial na avaliação do desempenho de modelos de aprendizado de máquina. Na Figura 4, são fornecidas uma representação visual da relação entre o *recall* e o *F1-score* em função da confiança das previsões do modelo. Esta análise permite avaliar de forma mais abrangente o desempenho do modelo e tomar decisões informadas sobre sua eficácia em diferentes contextos de aplicação.

Figura 4 – Curvas de confiança *recall* e confiança F1



Fonte: Autor (2024).


Na Figura 4, são apresentadas as curvas de confiança referentes ao modelo. Dividida em duas Subfiguras.

Na Subfigura A são fornecidas informações sobre a confiança do *recall*, que representa a certeza que o modelo possui em suas previsões. Para as classes *gun* e *knife*. É possível perceber que as linhas de confiança estão bastante próximas, o que indica uma confiança semelhante do modelo na detecção dessas duas classes. A linha azul representa a média de todas as classes, indicando simplesmente que o modelo fez uma detecção, sem distinguir entre as classes específicas. O *recall* máximo alcançado pelo modelo em todas as classes foi de 91,5 % sendo, 89,3 % para armas de fogo e 94,8 % para facas.

Em relação à Subfigura B, é apresentado um gráfico de relativo à curva de confiança do *F1-score*, que correlaciona a confiança do modelo com sua pontuação F1. Semelhante à Subfigura A, são exibidas três linhas, representando as classes de *gun*, *knife* e *background*. Observa-se que todas as classes atingiram um *F1-score* máximo de 0.8999 ou 89,99 %.

Na Figura 5, são apresentados os resultados das curvas de precisão-*recall* e precisão-confiança.

Figura 5 – Curvas de precisão-*recall* e precisão-confiança




Fonte: Autor (2024).

A Figura 5 é dividida em duas Subfiguras. Na Subfigura A, são apresentados os dados relacionados à precisão em relação à curva de *recall*. Os valores de *Average Precision* (AP) para as classes *Gun* e *Knife* são, respectivamente, 0,907 e 0,955, evidenciando uma maior precisão para a classe *Knife*.

Na Subfigura B, é apresentado um gráfico da curva de confiança da precisão. Nesse gráfico, observa-se que a curva referente às armas aumenta rapidamente. Para as facas, também há um aumento rápido, porém, com uma leve queda antes de alcançar alta precisão.

Visando realizar uma análise visual das detecções realizadas pelo modelo, na Figura 6 são apresentados exemplos das detecções de armas de fogo e facas em algumas imagens livres de direitos autorais.

Figura 6 – Amostra de resultados.



Fonte: Adaptado de Standret (2022), FromKazanWithLove (2021), Guruxox (2018), Foto-Artist (2023).

Na Figura 6, são ilustradas algumas detecções feitas pelo modelo para ambas as classes às quais foi treinado. Na Subfigura A, é apresentada a imagem de um cozinheiro segurando duas facas de cozinha, com as áreas delimitadas pelas *bounding boxes* indicando as detecções realizadas pelo modelo. Cada caixa exibe a classe do objeto detectado e sua precisão correspondente. Na Subfigura B, ocorre uma situação semelhante, porém, o cozinheiro está segurando apenas uma faca, que também foi detectada pelo modelo. Na Subfigura C, são mostradas detecções de armas de fogo, com quatro armas identificadas. Novamente, as *bounding boxes* destacam a classe da arma e sua precisão. Por fim, na Subfigura D, são apresentadas duas pessoas empunhando armas de fogo, ambas detectadas pelo modelo.

Por fim, na Figura 7 é retratado um ataque conhecido como Massacre de Columbine, ocorrido em 20 de abril de 1999 ocorrido na Columbine High School, Colorado.

Figura 7 – Detecção de ataque em Columbine.



Fonte: Adaptado de Stephen Zimmerman (2022).

A partir da Figura 7 é possível verificar duas pessoas, no caso, os responsáveis pelo ataque em Columbine, empunhando armas. Uma das armas o modelo conseguiu identificar sem muitos problemas, alcançando uma precisão de 85 %. No entanto, a arma do outro responsável não foi detectada devido a má qualidade da imagem. Com base na metodologia adotada e nos resultados obtidos, serão discutidas a seguir as conclusões alcançadas e sugestões para possíveis trabalhos futuros.

6. CONCLUSÕES E SUGESTÕES DE TRABALHOS FUTUROS

Conforme discutido ao longo deste trabalho, é possível perceber que o problema de ataques às escolas ocorrem a alguns anos, porém a frequência vem aumentando nos últimos anos, isso evidencia a necessidade de melhorias na segurança de lugares, especialmente em escolas. A Visão Computacional emerge como uma ferramenta promissora para lidar com esse problema, possibilitando a análise de imagens e a detecção precoce de possíveis ameaças.

A implementação do modelo proposto alcançou uma acurácia de 86,2 %, indicando sua eficácia na maioria dos casos. No entanto, há espaço para melhorias, especialmente em cenários desafiadores.

Além disso, durante este estudo, foi desenvolvida uma API utilizando o Django Rest Framework para facilitar o acesso e uso do modelo, o que pode simplificar sua implementação e integração em sistemas de segurança existentes. Esta API permite que outras aplicações e sistemas possam utilizar facilmente as capacidades do modelo de detecção desenvolvido, ampliando assim seu potencial de aplicação e impacto na segurança escolar.

Para trabalhos futuros, é crucial concluir a implementação e realizar testes práticos da ferramenta desenvolvida, validando sua eficácia no mundo real. Além disso, aprimorar o modelo para lidar com desafios específicos e explorar novas oportunidades de pesquisa e desenvolvimento no campo da Visão Computacional aplicada à segurança pública é algo bastante viável a ser realizado.

REFERÊNCIAS

AL-OBIDI, D.; KACMAZ, S. Facial features recognition based on their shape and color using yolov8. In: IEEE. *2023 7th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*. [S.l.], 2023. Citado na página 16.

BÖCKLER, N. et al. Same but different? developmental pathways to demonstrative targeted attacks—qualitative case analyses of adolescent and young adult perpetrators of targeted school attacks and jihadi terrorist attacks in germany. *International journal of developmental science*, IOS Press, v. 12, n. 1-2, p. 5–24, 2018. Citado na página 13.

CATTAPAN, P. Uma análise crítica dos fenômenos do bullying e do terrorismo. *Revista Iluminart*, n. 18, 2020. Citado na página 14.

Cidade Verde. *Proposta estabelece plano de evacuação em caso de ataques em escolas do Piauí*. 2023. <<https://cidadeverde.com/noticias/389874/proposta-estabelece-plano-de-evacuacao-em-caso-de-ataques-em-escolas-do-piaui>>. Acessado em 19/02/2024. Citado na página 14.

DESHPANDE, D. et al. Next-gen security: Yolov8 for real-time weapon detection. In: IEEE. *2023 7th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)*. [S.l.], 2023. p. 1055–1060. Citado na página 17.

Django Software Foundation. *Documentação do Django*. Django Software Foundation, 2023. Acessado em: 10 de março de 2024. Disponível em: <<https://docs.djangoproject.com/pt-br/5.0/#:~:text=Documenta%C3%A7%C3%A3o%20do%20Django%20%C2%B6%201%20Primeiros%20passos%20%C2%B6,O%20processo%20de%20desenvolvimento%20%C2%B6%20...%20Mais%20itens>>. Citado na página 20.

ERLANDSSON, Å.; MELOY, J. R. The swedish school attack in trollhättan. *Journal of forensic sciences*, Wiley Online Library, v. 63, n. 6, p. 1917–1927, 2018. Citado na página 13.

FIELDING, R. T. *Architectural Styles and the Design of Network-based Software Architectures*. Tese (Doutorado) — University of California, Irvine, 2000. Citado na página 25.

FOTOARTIST. *Brutal Cowboy Cowgirl Revolvers Ranch People Guns Wild West Lifestyle*. Depositphotos, 2023. Acessado em 05 de março de 2024. Disponível em: <<https://depositphotos.com/id/photo/brutal-cowboy-cowgirl-revolvers-ranch-people-guns-wild-west-lifestyle-654387220.html>>. Citado na página 30.

FROMKAZANWITHLOVE. *crime*. FreePik, 2021. Acessado em: 10 de março de 2024. Disponível em: <https://www.freepik.es/fotos-premium/retrato-chef-moda-cuchillo-bandana-concepto-cocina-alta-cocina_21890341.htm>. Citado na página 30.

GUPTA, L. *REST API Tutorial*. 2024. Accessed on February 10, 2024. Disponível em: <<https://restfulapi.net>>. Citado na página 18.

GURUXOX. *Group People Practice Gun Shoot Target Outdoor Shooting Range Civilian*. Depositphotos, 2018. Acessado em 05 de março de 2024. Disponível em: <<https://depositphotos.com/id/photo/group-people-practice-gun-shoot-target-outdoor-shooting-range-civilian-225446618.html>>. Citado na página 30.

Instituto Sou da Paz. *ATAQUES EM ESCOLAS: CASOS COM USO DE ARMAS DE FOGO FORAM TRÊS VEZES MAIS LETAIS QUE OS COM ARMAS BRANCAS*. 2023. <<https://soudapaz.org/noticias/ataques-em-escolas-casos-com-uso-de-armas-de-fogo-foram-tres-vezes-mais-letais-que-os-com-armas-brancas/>>. Acessado em 12/10/2023. Citado na página 10.

MADFIS, E. “it’s better to overreact”: School officials’ fear and perceived risk of rampage attacks and the criminalization of american public schools. *Critical Criminology*, Springer, v. 24, p. 39–55, 2016. Citado na página 10.

MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à visão computacional usando opencv. *Revista de Informática Teórica e Aplicada*, v. 16, n. 1, p. 125–160, 2009. Citado na página 18.

MARR, D. *Vision: A Computational Investigation into the Human Representation and Processing of Visual Information*. San Francisco: W. H. Freeman, 1982. xvi + 397 p. Citado na página 18.

MkDocs. *Django REST framework*. MkDocs, 2022. Acesso em 05 de março de 2024. Disponível em: <<https://www.django-rest-framework.org/>>. Citado na página 20.

PIXABAY. *Guerra, Deserto, Armas, Feira de Armas*. Pixabay, 2023. Acesso em 05 de março de 2024. Disponível em: <<https://pixabay.com/pt/photos/guerra-deserto-armas-feira-de-armas-1447026/>>. Citado na página 19.

Portal o Dia. *Ameaças em escolas: Piauí registrou 12 ocorrências e seis menores já foram apreendidos*. 2023. <<https://portalodia.com/noticias/piaui/ameacas-em-escolas-piaui-registrou-12-ocorrencias-e-seis-menores-ja-foram-apreendidos-398150.html>>. Acessado em 19/02/2024. Citado na página 14.

Roboflow. *Gun-Knife Thesis Dataset*. 2023. Accessed: February 04, 2024. Disponível em: <<https://universe.roboflow.com/crime-detection-zbmr9/gun-knife-thesis/dataset/3>>. Citado 3 vezes nas páginas 24, 25 e 27.

SANDBERG, S. et al. Stories in action: The cultural influences of school shootings on the terrorist attacks in norway. *Critical Studies on Terrorism*, Taylor & Francis, v. 7, n. 2, p. 277–296, 2014. Citado na página 14.

STANDRET. *crime*. FreePik, 2022. Acessado em: 10 de março de 2024. Disponível em: <https://br.freepik.com/fotos-premium/chef-de-uniforme-branco-em-pe-na-cozinha-segurando-facas-nas-maos_26055680.htm?log-in=google>. Citado na página 30.

Stephen Zimmerman. *Hate Unleashed: Massacre at Columbine*. Stephen Zimmerman, 2022. Acessado em 18 de março de 2024. Disponível em: <<https://stephenzimmerman.com/massacre-at-columbine>>. Citado na página 31.

Ultralytics. *Ultralytics YOLOv8 Docs*. 2024. <<https://docs.ultralytics.com/pt>>. Citado 2 vezes nas páginas 20 e 25.

VASANTHA, S. et al. Performance analysis of object detection algorithms for multi-person identification. In: IEEE. *2023 7th International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)*. [S.l.], 2023. p. 1–6. Citado na página 16.

ZOU, Z. et al. Object detection in 20 years: A survey. *Proceedings of the IEEE*, IEEE, 2023. Citado na página 19.