

Detecção de drone com auxílio de rede neural convolucional

Vinícius Ormianin Arantes Sousa¹, Kaleb Duarte Costa¹ e Alvaro José Damião²

¹Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

²Instituto de Estudos Avançados (IEAv), São José dos Campos/SP – Brasil

Resumo – O aumento do uso de drones é notável tanto em atividades militares como em várias atividades do dia a dia. No entanto, a dificuldade em detectar esses dispositivos tem se tornado uma preocupação quando se trata de proteger áreas sensíveis contra voos de drones desconhecidos. Além desses desafios, o fato de os drones poderem voar à noite acrescenta uma camada adicional de dificuldade à vigilância e à preservação de informações. Este artigo explora o uso de um feixe expandido de laser de CO₂ como iluminador, em laboratório, direcionado a um drone voando em um ambiente controlado, com o objetivo de capturar imagens no espectro de infravermelho distante (LWIR). As imagens obtidas foram usadas para treinar uma rede neural convolucional (CNN) usando a arquitetura YOLO (*You Only Look Once*). Ao final foi possível demonstrar a possibilidade de utilizar essa abordagem na detecção de drones quando iluminados por uma fonte de energia.

Palavras-Chave – Drone, Detecção, YOLO

I. INTRODUÇÃO

A utilização de drones tem aumentado sensivelmente seja em empregos militares, quanto em atividades civis rotineiras. Prova disso é o grande aumento de indústrias fabricantes desse tipo de vetor aéreo. Entretanto, existe um potencial crescente para pequenos drones serem utilizados com fins ilegais. Por exemplo, em muitos locais e áreas, o sobrevoo de drones pode prejudicar o bom andamento de determinada atividade, naquele ambiente. Áreas militares, industriais, aeroportos, entre outros locais, que requerem proteção ou sigilo. Existem ainda, drones com a capacidade e propósito de transporte de itens bélicos.

Exemplos de sobrevoo em área irregular despertam preocupações em autoridades ao redor de todo o mundo. Com vistas a conscientizar e minimizar condutas irregulares, por parte dos operadores de veículos remotamente pilotados, órgãos responsáveis pela segurança de voo vêm, ao longo dos últimos anos, elaborando e aplicando legislações cada vez mais rígidas. [1]

Neste contexto, a dificuldade em detectar esses dispositivos devido sua baixa RCS e emissão eletromagnética tem se tornado uma preocupação crescente para a segurança e defesa de áreas sensíveis. [2][3]

Atualmente são inúmeras as técnicas desenvolvidas na tentativa de detectar drones em diversos locais. Tecnologias no espectro visível são amplamente empregadas para a detecção deste tipo de plataforma, porém seu desempenho é limitado durante a noite, em ambientes com fundos complexos e em condições climáticas adversas. [4]

Considerando essa dificuldade na detecção no período noturno, este artigo propõe a utilização de um feixe de laser de CO₂ como iluminador, direcionado para um drone em voo em um ambiente controlado, com o objetivo de capturar imagens no espectro de infravermelho distante (LWIR). A escolha desse espectro é motivada pela capacidade do LWIR em fornecer informações térmicas precisas, permitindo identificar a presença de drones mesmo em condições de baixa luminosidade, ou com fundos complexos.

As imagens obtidas a partir do iluminador foram usadas para treinar uma rede neural convolucional utilizando a arquitetura YOLO [2], amplamente reconhecida na literatura pela sua eficácia e rapidez em tarefas de detecção em tempo real. Por meio deste treinamento, buscou-se validar a rede neural e demonstrar a viabilidade dessa abordagem na detecção de drones quando iluminados por uma certa fonte de energia, proporcionando assim uma melhoria significativa na detecção em ambientes noturnos.

Ao explorar essa abordagem e considerando as dificuldades enfrentadas para a detecção desse tipo de plataforma, espera-se com este artigo contribuir para o desenvolvimento de soluções eficazes de detecção de drones em ambientes noturnos, fortalecendo a segurança de áreas sensíveis e proporcionando maior proteção contra estas possíveis ameaças.

II. MATERIAIS E MÉTODOS

No experimento realizado utilizou-se um drone do tipo quadricóptero, de dimensões 27 x 27 x 5,5 cm (Fig. 1), o qual foi preso ao chão e ao teto, de forma que permanecesse com mobilidade reduzida nos três eixos. O drone permaneceu preso com o auxílio de cabos, mosquetões e ilhoses a uma altura de 0,9 m do chão, podendo voar em um raio de 0,1 m no eixo vertical e 0,3 m no eixo horizontal.




Fig. 1. Drone preso para manter a mobilidade reduzida durante o voo.

O iluminador do drone foi um laser de CO₂, da marca Synrad (Fig. 2), com comprimento de onda de 10,6 μm , com potência máxima de 30 W. Para o experimento foi mantida a potência a 40 %, que corresponde a 12 W. A opção por este tipo de laser e este comprimento de onda, se deu pela restrição de equipamentos disponíveis para o experimento.

Porém, o iluminador utilizado possui características que o torna apropriado para detecção de calor ou vigilância em longas distâncias. Outra característica importante é a alta potência disponível para a utilização desse laser. À medida que a potência do laser é aumentada, a reflexão do comprimento de onda no objeto (neste caso, o drone), torna-se mais evidente, sendo apresentada pelo sensor como se fosse um aumento da temperatura da superfície e permitindo que a câmera termal capture os diversos pontos da reflexão, como se fossem pontos mais ou menos quentes.



Fig. 2. Laser de CO₂ da marca Synrad, de 30 W, com potência ajustável.

Pelo fato de o laser utilizado ser emitido como um feixe com diâmetro de, aproximadamente, 3,5 mm na abertura de saída, e mesmo havendo uma divergência de ângulo total devido à difração de 4 mrad, foi necessária a utilização de um arranjo óptico com duas lentes côncavo-convexas (Fig. 3), com o objetivo de expandir o feixe laser. [5] O drone permaneceu a uma distância de 6 m da saída do feixe laser da segunda lente do conjunto (lente mais próxima do drone).



Fig. 3. Conjunto óptico com duas lentes côncavo-convexas.

Para obtenção das imagens no infravermelho longo (LWIR) utilizou-se a câmera térmica radiométrica WIRIS Pro, da marca Workswell (Fig. 4). Essa câmera foi escolhida por ser sensível aos comprimentos de onda na faixa de 7,5 a 13,5 μm . [6]



Fig. 4. Câmera termal radiométrica Wiris Pro, da marca Workswell.

O diagrama apresentado na figura 5 ilustra a disposição da câmera, do laser e do drone no experimento.




Fig. 5. Diagrama do experimento.

A extração de imagens de vídeo foi feita com o auxílio do *software* ThermoLab, o qual permite reproduzir os arquivos obtidos no formato “.wseq”, gerados pela câmera Wiris Pro. [6]

As imagens obtidas foram rotuladas utilizando o *software* LabelImg, o qual, após a determinação das caixas delimitadoras (*bounding boxes*), gera um arquivo “.txt”, que fornece as informações da classe do objeto selecionado e das coordenadas da posição do objeto na imagem.

Com o objetivo de permitir o processamento de dados e visão computacional, foram utilizadas duas bibliotecas Python: NumPy (*Numerical Python*), que oferece facilidades para trabalhar com dados numéricos, como multiplicação de matrizes, convoluções, além de ser capaz de integrar junto à Darknet (detalhada abaixo); e OpenCV (*Open Source Computer Vision Library*), que fornece ferramentas para a manipulação eficiente de dados de imagem, bem como a análise e visualização dos resultados do treinamento.

O treinamento de rede neural convolucional foi realizado a partir do algoritmo de detecção YOLOv4 (*You Only Look Once - 4ª versão*). Esta ferramenta redimensiona a imagem para 448 x 448, executa uma única rede convolucional na imagem e limita as detecções resultantes pelo grau de confiança do modelo. [7]

Para treinar e implementar a rede neural convolucional YOLO utilizou-se o *framework* de aprendizado profundo Darknet, o qual consiste em uma estrutura de rede neural de código aberto escrita em C e em CUDA. Para executar esse tipo de ferramenta foi necessário utilizar a plataforma do Google Colaboratory, que fornece o uso de GPU (*Graphics Processing Units*). Essa plataforma permite executar o treinamento da rede neural YOLO usando a Darknet com velocidade aprimorada e capacidade de processamento paralelo, permitindo treinar o modelo mais rapidamente e de forma mais eficiente.

Ao final do experimento, com o objetivo de validar a rede neural, utilizou-se o *software* Visual Studio Code, o qual reproduz a imagem escolhida com o objeto de interesse que, ao ser detectado tem uma “caixa” delimitadora com uma probabilidade de acerto. Ou, a imagem sem nenhuma delimitação que significa que nada foi detectado.

III. METODOLOGIA

Neste experimento, a metodologia adotada envolveu a busca por um sinal gerado da reflexão do feixe de laser de

CO₂ no drone em movimento, captado pela câmera de infravermelho.

Deixa-se bem claro que o objetivo deste artigo não pretendeu realizar a classificação dos objetos, apesar de utilizar a classificação como métrica para avaliar os resultados. O objetivo do experimento se restringiu à busca por um sinal refletido ou espalhado do laser pelo drone, com o emprego de uma câmera infravermelha.

A Tabela 1 apresenta as fases do voo do drone, no qual foi possível avaliar o comportamento espectral do drone: a) desligado sem ser iluminado; b) ligado sem ser iluminado; c) ligado sendo iluminado; d) desligado sendo iluminado pelo laser de CO₂; e, novamente, e) ambos desligados (laser e drone).

TABELA 1. FASES DO EXPERIMENTO

FASE	DRONE	LASER	TEMPO DE VÍDEO
1	DESLIGADO	DESLIGADO	0 A 9,5S
2	LIGADO	DESLIGADO	9,5 A 25S
3	LIGADO	LIGADO	25 A 45S
4	DESLIGADO	LIGADO	45 A 53S
5	DESLIGADO	DESLIGADO	53 A 54S

Em um primeiro momento, buscou-se verificar se haveria diferença espectral nas imagens quando o drone voava sem a iluminação pelo laser e quando ele passava a ser iluminado pelo laser. A figura 6 apresenta um gráfico que demonstra que houve, sim, diferença espectral, evidenciado pela alteração de temperatura média e pelos picos de temperatura observados pela câmera infravermelha.

Observa-se, de forma clara, que durante as fases 1 e 2, quando o laser ainda não havia sido ligado, as temperaturas máximas observadas na imagem não passam de 27,7 °C. Porém, ao ligar o laser, durante as fases 3 e 4 do experimento, e o seu feixe refletir no drone, observam-se picos de temperatura ocasionados pelo reflexo do laser no drone. E na fase 5, quando o laser é desligado, observa-se novamente uma estabilidade na temperatura, não ultrapassando os 29,5 °C.




Fig. 6. Temperatura em função do tempo, de acordo com cada fase do experimento.

Ressalta-se que o *software* Thermolab, componente do sensor da câmera Wiris Pro, permite uma análise com base em diferenças de temperatura. Análise esta, que não significa que a temperatura na superfície do objeto é, de fato, aquela apresentada pelos indicadores da ferramenta. Assim, pode-se entender que, fisicamente, o que ocorre é a reflexão do comprimento de onda no objeto e a detecção desse

comprimento de onda pelo sensor. Ou ainda, a detecção de comprimentos de onda diferentes do emitido, causados pelo processo físico de absorção de energia pelo objeto. A lei de Wien permite o entendimento desse fenômeno ao representar a relação entre a temperatura de um objeto e o comprimento de onda onde ocorre a máxima radiação de energia de um corpo negro [8], conforme (1):

$$\lambda_{max} \cdot T = b \quad (1)$$

Onde b é a constante de Boltzmann, que possui o valor de $2,897772 \cdot 10^{-3}$ m.K.

As temperaturas apresentadas no gráfico, portanto, são representações dos comprimentos de onda oriundos do drone após sofrerem reflexão e absorção da energia recebida do laser de CO₂. Esses diferentes comprimentos de onda detectados pelo sensor são consequência dos diferentes ângulos das superfícies do objeto, das reflexões entre pás, motores e corpo do drone. E a absorção de parte da energia incidida pode ser explicada pelos diferentes materiais dos quais o drone foi feito, como liga de magnésio, fibra de carbono e compósitos. [9]

Sabendo, portanto, que há diferença no sinal obtido pelo sensor infravermelho quando ocorre a iluminação pelo laser, buscou-se verificar qual a temperatura máxima apresentada pelo *software* quando o drone estava voando, sem ser iluminado. Dessa forma, até 0,1s antes do drone passar a ser iluminado a temperatura máxima identificada pelo sensor como resposta do comprimento de onda observado foi de 27,7 °C.

A partir daí foi possível estabelecer um valor mínimo e ajustar o *range* de temperatura a ser apresentado pela interface utilizada durante o experimento. Assim, quando o drone entrava no feixe do laser de CO₂, sinais eram observados nas imagens. A figura 7 mostra a imagem da forma como o *software* ThermoLab apresenta ao usuário, sem ajuste no *range* de temperatura. Já a figura 8 teve a escala de temperatura ajustada para mostrar apenas as áreas do drone que estão representadas como acima de 27,7 °C.

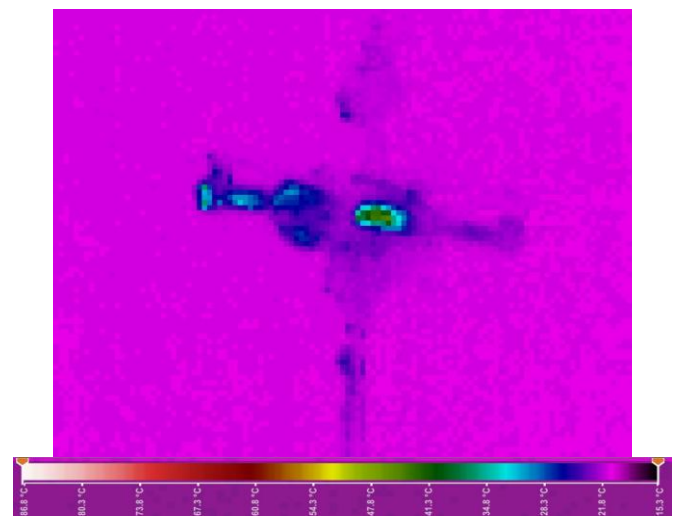


Fig. 7. Drone iluminado pelo laser de CO₂, sem ajuste na escala de temperatura.




Fig. 8. Drone iluminado pelo laser de CO₂ com ajuste na escala de temperatura, acima de 27,7 °C.

Observa-se, desse modo, que esse ajuste de temperatura é utilizado como se fosse um filtro óptico passa faixa, no qual o sinal representado pelas temperaturas abaixo de 27,7 °C, e que corresponde, neste experimento, à intensidade radiante do drone sem ser iluminado pelo laser, é “bloqueada”. E a faixa de interesse e que aparece nas imagens, é o sinal da temperatura correspondente à intensidade radiante do drone quando iluminado por um feixe laser com comprimento de onda de 10,6 μm.

O conjunto de imagens foi gerado a partir de um vídeo de 55 s, do qual foram extraídas um total de 98 imagens, divididas da seguinte maneira e de forma aleatória: 69 imagens para treinamento, 15 para validação e 14 para ativação da rede neural convolucional, conforme Tabela 2. Por se tratar de uma arquitetura (YOLO) que já possui pesos pré-definidos, a quantidade de imagens pode ser considerada satisfatória. Diferentemente seria se a rede fosse treinada do zero, quando seria necessário um *dataset* maior.

Para definir qual a porcentagem das imagens seria destinada para cada fase (treinamento, validação e ativação da rede neural), foram consultadas duas fontes. Uma das fontes apresentou a quantidade ideal como sendo 60% para treinamento e 40% para validação [10]. Já a segunda fonte considera como ideal a proporção 80% para treinamento e 20% para validação [11]. Assim sendo, as quantidades foram divididas de modo que fosse preservada uma porcentagem que estivesse em coerência com as encontradas na literatura, ou seja, 70% das imagens para treinamento, 15% para validação e 15% para ativação.

TABELA 2. DIVISÃO DAS IMAGENS UTILIZADAS NO TREINAMENTO, VALIDAÇÃO E ATIVAÇÃO DA REDE NEURAL CONVOLUCIONAL.

FASE	IMAGENS	PORCENTAGEM
TREINAMENTO	69	70,4%
VALIDAÇÃO	15	15,3%
ATIVAÇÃO	14	14,3%

Todas as imagens foram rotuladas com o auxílio do *software* LabelImg, tendo classificado cada rótulo manualmente como “drone” nas áreas do drone que foram iluminadas pelo laser de CO₂ com temperatura acima de 27,7 °C e como “não drone” nas áreas que apareceram na imagem e que não fazem parte da estrutura do drone (ilhós, mosquetão e cabo).

Com as imagens devidamente rotuladas foi possível iniciar o treinamento da rede neural, o qual consistiu em 4.000 épocas de treinamento, com duração total de 14 horas e 45 minutos.

Ao final do treinamento foi possível avaliar, por meio da métrica “mAP” (*mean Average Precision*), fornecida pela própria rede neural, a precisão do treinamento, ou seja, a qualidade das detecções realizadas pelo modelo e a recuperação, que é a capacidade do modelo de detectar corretamente todos os objetos em cada classe específica.

Observa-se na figura 9 uma visão do treinamento, no qual, em azul, é possível verificar a taxa de erro (*loss*), com um comportamento abaixo de 1% a partir de 1.080 épocas de treinamento. E em vermelho é possível analisar a precisão média, variando entre 100% e 85% e finalizando o treinamento com 85%. Destaca-se que o tempo total de detecção realizado pela rede neural foi de 1 segundo.




Fig. 9. Desempenho da rede neural no treinamento, observado pela função da taxa de erro (*loss*) em azul, em função das épocas de treinamento. Em vermelho, ainda, é possível acompanhar a média de precisão entre as classes.

A Tabela 3 apresenta as informações finais do treinamento, com as classes “drone” e “não drone”, a precisão média para cada classe (*ap* – *average precision*), a média das precisões entre as duas classes (*mAP* – *mean Average Precision*), e IoU (*Intersection over Union*), que mede a sobreposição entre as caixas delimitadora previstas e as caixas delimitadoras reais.

TABELA 3. INFORMAÇÕES APÓS O TÉRMINO DO TREINAMENTO

Classes	Ap (%)	mAP (%)	IoU (%)	Precisão	Recall	F1 Score
Drone	100	85	73,16	1,00	0,67	0,80
Não drone	70					

Outras métricas do treinamento que podem ser analisadas são as métricas de Sensibilidade (*Recall*), Precisão (*Precision*) e Pontuação F1 (*F1 Score*). A Tabela 3 demonstra que no treinamento deste experimento atingiu-se, após as 4.000 épocas treinadas, um índice de 100% de precisão, o que indica que todas as detecções feitas pelo modelo para esse limiar de confiança (0,25) estão corretas; 67% de sensibilidade (*Recall*), que significa que o modelo detectou corretamente 67% dos objetos reais e; 80% de pontuação F1 (*F1 Score*), que é uma medida combinada de precisão e sensibilidade.

Informações adicionais ainda podem ser analisadas, observando que precisão média para detecção dos objetos identificados como “drone” foi de 100% e de “não drone”, 70%.

Para este artigo, como o critério de detecção é a predição do alvo sobre o alvo inteiro ou somente parte dele, o foco do trabalho foi somente na detecção propriamente dita e não com o grau de correção da posição. Dessa forma, foram levadas em consideração apenas as métricas de sensibilidade, precisão e a pontuação F1. [12]

Realizado o treinamento, a fase seguinte do experimento foi executar a ativação da rede neural convolucional, com o objetivo de verificar se os objetos presentes na imagem foram detectados pela rede após o treinamento. Conforme apresentado na Tabela 2, foram utilizadas 14 imagens para ativação.

Os objetos que foram detectados pela rede, apresentam um retângulo delimitador com a indicação da classe que foi detectada e com a probabilidade ou confiança atribuída pelo modelo a cada detecção. Ou seja, essa probabilidade indica o quão confiante o modelo está de que a detecção é correta para uma determinada classe de objeto. Essa probabilidade é apresentada por um número de 0 a 1 ao lado da classe, conforme a figura 10.




Fig. 10. Exemplo do resultado apresentado na ativação da rede neural convolucional.

A Tabela 4 apresenta um resumo dos resultados da ativação da rede neural convolucional treinada, utilizando as imagens escolhidas. Nesta tabela não foram computadas as imagens que não constaram nenhuma detecção, num total de 4, ou seja 28,5% do total. As outras 10 imagens apresentaram

detecções em 16 sinais detectados pelo sensor infravermelho, representando 72,5%.

TABELA 4. GRAU DE CONFIANÇA DO MODELO PARA CADA DETECÇÃO

	Detecção Correta		Detecção Incorreta	
	Drone	Não Drone	Drone	Não Drone
Grau de confiança	0,68	0,54	0,71	0,93
	0,64	0,74		0,95
	0,60	0,56		
	0,62	0,96		
	0,81			
	0,66			
	0,90			
	0,72			
	0,90			

Das detecções, 13 foram classificadas de forma correta e 3 de forma incorreta. As detecções ocorridas de forma acertada pela rede neural, apresentaram taxas de confiança do modelo que variaram entre 0,54 e 0,96, com uma média dessa taxa de 0,71.

A sequência de figura 11 apresenta as detecções corretas da rede neural tanto para detecção das áreas em que estavam drones como das áreas que apresentam partes que não correspondiam ao drone.




Fig. 11. Junção de todas as imagens que apresentaram detecção e correta classificação dos objetos.

Na figura 12, pode-se observar as duas imagens que apresentaram sinais, mas que foram classificadas de forma incorreta.




Fig. 12. Imagens que apresentaram sinais classificados de forma incorreta.

IV. OBSERVAÇÕES FINAIS

Como análise dos resultados obtidos, ressalta-se a capacidade da câmera Wiris Pro que, com o auxílio do *software* Thermolab permitindo a limitação das temperaturas máximas e mínimas de interesse, atua como se fosse um filtro óptico passa faixa, demonstrando a refletividade do laser de CO₂ no drone.

Considerando que resultados superiores a 0,8 para sensibilidade, e superiores a 0,7 para precisão e pontuação F1, são considerados bons resultados, conforme consulta na literatura, pode-se verificar que, para a quantidade de imagens presentes no *dataset* disponível, os resultados do treinamento foram satisfatórios.

Com bons resultados obtidos no treinamento, a validação também pode ser considerada interessante, haja vista que mais de 70% das imagens apresentaram alguma detecção de sinal, com uma média de 70% na confiança de acerto pelo modelo.

Os resultados analisados podem indicar que, havendo uma quantidade maior de imagens e realizando um voo com o drone livre de ancoragens, espera-se que a rede neural fique ainda mais bem treinada, já que a amostra será maior e de melhor qualidade, reduzindo a chance de detecção de falsos positivos.

Empregando a metodologia proposta, pode-se testar o experimento em campo, variando a distância e perfil de voo de forma que o drone atravesse o feixe expandido do laser e reflita sinal suficiente para ser detectado pela câmera. Outra forma de melhorar a metodologia proposta é realizar uma coleta de imagens com a câmera em movimento. Dependendo da resolução da câmera e capacidade de captura de imagens de qualidade em movimento, pode ser possível validar a rede com o sensor “acompanhando” o alvo.

Outra oportunidade de melhoria para o experimento é a utilização de versões mais recentes e aprimoradas do algoritmo de detecção, como a YOLOv5, por exemplo. Essa versão apresentou algumas métricas mais apuradas que a YOLOv4. [13]

Por fim, após análise dos dados obtidos pelo treinamento, validação e ativação da rede neural, é possível demonstrar a possibilidade de utilizar essa abordagem na detecção de drones quando iluminados por uma fonte de energia, melhorando assim a detecção, principalmente em ambientes noturnos ou inseridos em locais com fundos complexos.

REFERÊNCIAS

- [1] FAB. Força Aérea Brasileira. DECEA atualiza normas de acesso de drones ao espaço aéreo brasileiro. Brasília: FAB, 2023. Disponível em: <https://www.fab.mil.br/noticias/mostra/41019/VOOS%20DE%20DRONE%20-%20DECEA%20atualiza%20normas%20de%20acesso%20de%20drones%20ao%20espa%C3%A7o%20a%C3%A9reo%20brasileiro>. Acesso em: 6 jul. 2023.
- [2] Singha, S., & Aydin, B. (2021). Automated drone detection using YOLOv4. *Drones*, 5(3), 95.
- [3] Dewangan, V., Saxena, A., Thakur, R., & Tripathi, S. (2023). Application of Image Processing Techniques for UAV Detection Using Deep Learning and Distance-Wise Analysis. *Drones*, 7(3), 174.
- [4] Misbah, M., Khan, M. U., Yang, Z., & Kaleem, Z. (2023, March). Tf-net: Deep learning empowered tiny feature network for night-time uav detection. In *International Conference on Wireless and Satellite Systems* (pp. 3-18). Cham: Springer Nature Switzerland.
- [5] An Excel Technology Company - SYNRAD. **Series L48 Lasers Operator's Manual: Model 48-1**. Mukilteo, WA - USA: SYNRAD. 2010. 102 p.
- [6] WORKSWELL (Czech Republic) (ed.). Workswell Wiris Pro: User Manual. FW Version: 1.3.8. ed. Czech Republic: [s. n.], 2020. 74 p. v. Version: 201215 EN.

- [7] REDMON, Joseph et al. You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 779-788.
- [8] BIRCH, G. C.; WOO, B. L. Counter Unmanned Aerial Systems Testing: Evaluation of VIS SWIR MWIR and LWIR passive imagers. Disponível em: <<https://www.osti.gov/servlets/purl/1342469>>. Acesso em: 28 ago. 2023.
- [9] HÖCHE, D. et al. Novel Magnesium Based Materials: Are They Reliable Drone Construction Materials? A Mini Review. *Frontiers in Materials*, v. 8, 23 abr. 2021.
- [10] Sambolek, S., & Ivasic-Kos, M. (2021). Automatic person detection in search and rescue operations using deep CNN detectors. *IEEE Access*, 9, 37905-37922.
- [11] Martinez-Alpiste, I., Golcarenenji, G., Wang, Q., & Alcaraz-Calero, J. M. (2021). Search and rescue operation using UAVs: A case study. *Expert Systems with Applications*, 178, 114937.
- [12] EICK, F. Avaliação de Rede Neural Convolucional para Detecção Automática de Pessoas em Ambiente Aquático com Uso de Imagens no Infravermelho. Dissertação de Mestrado—Instituto Tecnológico de Aeronáutica (ITA): [s.n.].
- [13] Aydin, B., & Singha, S. (2023). Drone Detection Using YOLOv5. *Eng*, 4(1), 416-433.