

# Geração de Dados Sintéticos para Treinamento de Modelos de Visão Computacional em Sistemas de *Detect and Avoidance* de Veículos Aéreos Não Tripulados

Bruno Binelli Ribeiro  
Universidade Federal de Santa  
Catarina – UFSC  
Araranguá, Santa Catarina, Brasil  
bruno.b.ribeiro@grad.ufsc.br

Pedro Augusto Reghelin  
Sfoggia  
Universidade Federal de Santa  
Catarina – UFSC  
Araranguá, Santa Catarina, Brasil  
pedroars.ufsc@gmail.com

Eduardo Cristaldo Panizzon  
Universidade Federal de Santa  
Catarina – UFSC  
Araranguá, Santa Catarina, Brasil  
eduardo.panizzon@grad.ufsc.br

Vinicius Wolosky Muchulski  
Universidade Federal de Santa  
Catarina – UFSC  
Araranguá, Santa Catarina, Brasil  
vinicius.muchulski@grad.ufsc.br

Fabício de Oliveira Ourique  
Queen Mary University of London –  
QMUL  
Londres, Santa Catarina, Reino Unido  
f.ourique@qmul.ac.uk

Antonio Carlos Sobieranski  
Universidade Federal de Santa  
Catarina – UFSC  
Araranguá, Santa Catarina, Brasil  
a.sobieranski@ufsc.br

Samoel Mirachi  
Global Drones  
Florianópolis, Santa Catarina, Brasil  
samoel@globaldrones.com.br

## Abstract

Detect and Avoid (D&A) systems play a central role in the operational safety of Unmanned Aerial Vehicles (UAVs), enabling autonomous aircraft to identify and avoid obstacles in real time. However, the training of computer vision models for D&A faces significant limitations due to the scarcity of real-world data, particularly in high-risk scenarios such as near-collisions or adverse weather conditions. Acquiring such data in real environments is operationally hazardous, financially unfeasible, and often ethically impractical. In this work, we propose an approach based on synthetic data generation using high-fidelity graphics engines, specifically Unreal Engine and Blender, which enables the controlled and safe recreation of a wide range of critical scenarios. We detail the pipeline for virtual environment construction, physical flight simulation, dynamic obstacle parameterization, and large-scale generation of FPV videos for training computer vision models. Also, we demonstrate preliminary results in these datasets using Convolutional Neural Networks as detectors to locate other drones in the UAV trajectory. The expected outcomes include increased model robustness, improved performance in risk-prone situations, and enhanced sim-to-real generalization. This work lays the foundation for the creation of an open synthetic dataset for D&A in UAVs.

## Keywords

Dados Sintéticos, Visão Computacional, Detect and Avoidance, Aeronaves Não-Tripuladas

## 1 Introdução

O avanço acelerado observado nas áreas de Processamento Digital de Imagens (PDI) e Visão Computacional (VC) ao longo da última década deve-se, além da evolução do hardware computacional, à

mudança de paradigma de métodos clássicos baseados em engenharia manual de características para abordagens fundamentadas em aprendizado profundo. Enquanto nos métodos clássicos era necessário conhecimento detalhado da natureza do problema e das técnicas de extração de características, no paradigma de aprendizado profundo essas representações passam a ser aprendidas automaticamente a partir dos dados por meio de processos iterativos de otimização, permitindo a extração hierárquica de características discriminativas de um *target* de interesse [1]. No entanto, conjuntos de dados de tamanho considerável e com ampla diversidade de casos são necessários para o treinamento eficaz desses modelos. A qualidade, a diversidade e a quantidade dos dados de treinamento são fatores determinantes para a capacidade de generalização dos modelos em cenários reais [2]. Na categoria de aprendizado profundo, destacam-se as Redes Neurais Convolucionais (CNNs) e, mais recentemente, Grandes Modelos Multimodais, que dependem intrinsecamente de datasets massivos para a extração de características semânticas complexas e para a realização de inferências robustas em ambientes dinâmicos e não estruturados.

Neste contexto, diversas áreas de aplicação podem se beneficiar significativamente da capacidade de generalização provida pelas técnicas de aprendizado profundo. Uma dessas áreas é a navegação autônoma em aeronaves não tripuladas (VANTs), na qual sistemas de Detect and Avoid (D&A) assumem um papel central na arquitetura de segurança de voo [3]. Esses sistemas têm como objetivo detectar, rastrear e classificar obstáculos no espaço aéreo, utilizando informações provenientes de múltiplos sensores, incluindo câmeras embarcadas. Mais do que um mecanismo de percepção visual, o D&A constitui o núcleo responsável pela tomada de decisão em tempo real, permitindo a execução de manobras evasivas autônomas frente a obstáculos estáticos, como infraestruturas e relevo,

e dinâmicos, como outras aeronaves e aves [4]. A robustez desse sistema é, portanto, um fator crítico para garantir a integridade do veículo em situações de risco, sendo um pré-requisito essencial para a viabilização de operações autônomas complexas e voos além da linha de visada visual (BVLOS).

No entanto, a aquisição de dados reais para o treinamento supervisionado de algoritmos de D&A apresenta barreiras logísticas, financeiras e operacionais significativas. A captura de imagens em cenários críticos, especialmente em situações de quase-colisão ou trajetórias de impacto iminente, é operacionalmente inviável devido ao elevado risco de danos ao equipamento, comprometimento da segurança operacional, prejuízos à infraestrutura e riscos a pessoas. Como consequência, os datasets reais disponíveis tendem a ser fortemente desbalanceados, com uma super-representação de voos em condições claramente seguras e uma escassez severa de exemplos associados a situações de perigo, o que limita a capacidade dos modelos de reagirem adequadamente quando confrontados com cenários críticos [5].

Para mitigar a escassez de dados críticos e o alto custo da coleta em campo, a geração de dados sintéticos apresenta-se como uma alternativa promissora. Este trabalho propõe a utilização de motores gráficos 3D de alta fidelidade, especificamente Unreal Engine e Blender, para a criação de ambientes virtuais realistas e controlados. Por meio dessas ferramentas, torna-se possível simular situações complexas, perigosas e altamente diversificadas. O objetivo é gerar vídeos em perspectiva de primeira pessoa (FPV), contendo dados que seriam inviáveis de serem obtidos em cenários reais, projetados especificamente para o treinamento e a validação de modelos de visão computacional, desde arquiteturas baseadas em CNNs até modelos visuais de maior complexidade. Neste contexto, avalia-se preliminarmente o processo de detecção de ameaças de interesse, como outros drones, a partir da linha de visada da câmera FPV de um VANT em ambiente simulado, utilizando redes neurais convolucionais.

## 2 Trabalhos Relacionados

O uso de dados sintéticos em visão computacional tem ganhado notoriedade com o avanço de motores gráficos realistas e novas técnicas de Sim-to-Real. O conceito de *domain randomization*, introduzido por Tobin et al. [6], fundamentou a ideia de que grande variabilidade sintética pode melhorar a generalização em cenários reais. Para aeronaves e UAVs, AirSim [7] e FlightForge [8] representam marcos importantes em simulação de voo de alta fidelidade. Outros datasets sintéticos relacionados incluem Sim2Air [9] e PAVeDS [10]. O que pode ser observado é que poucos trabalhos explicitamente exploram a utilização de dados sintéticos em D&A, especialmente em situações de perspectiva em primeira pessoa de vôo da aeronave. Essa limitação em trabalhos explorando especificamente D&A é a lacuna que este trabalho busca pesquisar.

## 3 Solução Proposta

A abordagem proposta neste trabalho consiste no desenvolvimento de um fluxo de geração de dados sintéticos, projetado para superar as limitações de segurança e custo inerentes à coleta de dados reais. A arquitetura da solução fundamenta-se na integração de ferramentas de modelagem e renderização 3D de alta fidelidade

para criar um ambiente simulado fotorealista. O objetivo central é replicar a física de voo e as características visuais de operações de VANTs, permitindo a síntese de datasets massivos que englobam desde voos nominais até situações de risco extremo, inviáveis de serem reproduzidas fisicamente.


O núcleo de simulação do ambiente é gerido pela Unreal Engine, escolhida por sua capacidade de renderização em tempo real e pelo sistema avançado de física. A engine é responsável por simular a dinâmica do drone e a perspectiva da câmera FPV, gerando as imagens que alimentam os modelos de visão computacional. Através de scripts de automação dentro da Unreal, é possível controlar programaticamente a posição do drone, a trajetória de voo e a interação com o ambiente, garantindo que a câmera capture a variabilidade necessária para a generalização do modelo.

Para assegurar a diversidade e a complexidade dos obstáculos a serem detectados, utiliza-se o Blender como ferramenta de modelagem complementar. Nesta etapa, são criados ou adaptados ativos 3D detalhados, variando desde outras aeronaves e drones de diferentes classes até elementos estáticos como linhas de transmissão, aves e estruturas urbanas. A integração facilitada entre o Blender e a Unreal Engine permite a importação de ativos com texturas de alta resolução e geometrias complexas, enriquecendo o cenário virtual com uma variedade de objetos que o sistema de Detect and Avoid deve ser capaz de identificar e classificar.

Por fim, pode-se apontar como um diferencial crítico desta solução, a capacidade de orquestrar cenários de "quase-colisão" e condições ambientais adversas de forma controlada. Como é possível construir o ambiente de inúmeras maneiras distintas, torna-se viável testar como os algoritmos reagiriam a condições atmosféricas adversas – como neblina densa, chuva e variação da posição solar – bem como a criação de trajetórias de colisão frontal ou lateral com obstáculos dinâmicos. Essa flexibilidade permite submeter os algoritmos de detecção a "casos de borda", preenchendo a lacuna de dados críticos que datasets reais raramente conseguem capturar. Dessa forma, é evidente que o ambiente simulado não atua como um substituto, mas como um amplificador de capacidades, assegurando que os algoritmos de Detect and Avoid sejam expostos e validados contra a imprevisibilidade inerente à operação aérea, garantindo a robustez necessária para a autonomia plena antes do primeiro voo físico.

## 4 Resultados Preliminares

Esta seção apresenta os resultados experimentais preliminares obtidos a partir do pipeline de geração de dados sintéticos proposto, bem como uma validação inicial da sua aplicabilidade no treinamento de modelos de visão computacional voltados a sistemas de Detect and Avoid (D&A). Inicialmente, foi desenvolvido um ambiente virtual tridimensional no qual são simuladas diferentes configurações de voo, cenários e obstáculos dinâmicos. A Fig.1 ilustra o estágio atual do ambiente simulado, destacando tanto a perspectiva geral do cenário quanto o nível de realismo visual alcançado. Observa-se que o uso combinado de Unreal Engine e Blender possibilita a criação de cenas com iluminação realista, variação de texturas, profundidade adequada e diversidade geométrica, características essenciais para a generalização de modelos baseados em aprendizado profundo.



(a) Perspectiva geral do ambiente.



(b) Exemplo de realismo presente no ambiente.

Figura 1: Estado atual do ambiente simulado.

A partir deste ambiente, foram gerados vídeos sintéticos em perspectiva de primeira pessoa (FPV), considerando diferentes trajetórias de voo, ângulos de aproximação e situações de risco, incluindo cenários de quase-colisão com outros UAVs. Esses vídeos foram automaticamente rotulados com informações de localização dos alvos de interesse, permitindo sua utilização direta em pipelines de treinamento supervisionado. Como prova de conceito, um modelo baseado em Redes Neurais Convolucionais (CNNs) foi treinado utilizando exclusivamente os dados sintéticos gerados. A Fig.2 apresenta exemplos de detecções realizadas pelo modelo, evidenciando a capacidade de identificar outros drones na trajetória de voo a partir das imagens FPV. Mesmo sem otimizações avançadas ou ajuste fino com dados reais, o modelo demonstrou comportamento consistente na localização dos alvos, indicando que os dados sintéticos preservam características visuais relevantes para a tarefa de D&A.

Embora os experimentos apresentados tenham caráter preliminar, os resultados obtidos reforçam a viabilidade do uso de dados sintéticos para o treinamento inicial de modelos de visão computacional em sistemas de Detect and Avoid. Esses achados corroboram a hipótese de que a exposição controlada a cenários críticos e raros, inviáveis de serem capturados em ambientes reais, pode contribuir significativamente para a robustez e a capacidade de generalização dos modelos, servindo como base para futuras avaliações quantitativas e estudos de transferência Sim-to-Real.

## 5 Considerações Finais

O presente trabalho delineou a estrutura e a implementação inicial de um fluxo para geração de dados sintéticos, visando mitigar a escassez de amostras críticas para sistemas de Detect and Avoidance em VANTs. A integração proposta entre a Unreal Engine e o Blender demonstra-se, nesta etapa de desenvolvimento, uma ferramenta viável para a criação de cenários realistas. O ambiente de simulação já configurado permite a reprodução segura da física de voo e a modelagem de situações de risco, estabelecendo as bases necessárias para a constituição de datasets robustos que seriam inviáveis de se obter via apenas a coleta de dados físicos.




Figura 2: Detecções de ameaça de interesse utilizando CNNs

A principal contribuição esperada deste trabalho em andamento reside na validação de como modelos de visão computacional podem beneficiar-se significativamente da exposição a eventos raros, imprevisíveis e catastróficos gerados virtualmente. A arquitetura desenvolvida até o momento foca na fidelidade visual, preparando o terreno para que os algoritmos de detecção aprendam a generalizar características em contextos de alta complexidade antes do contato com o mundo real.

As etapas subsequentes da pesquisa concentram-se na geração massiva do conjunto de dados e no treinamento das primeiras arquiteturas de referência para avaliação de desempenho, bem como em sua disponibilização pública para toda a comunidade científica e demais interessados. Futuramente, pretende-se quantificar a eficácia da transferência de aprendizado Sim-to-Real, comparando a inferência dos modelos treinados sinteticamente contra vídeos de voos reais, além de expandir a simulação para incluir sensores complementares.

## Referências

- [1] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. *Nature*, 521(7553):436–444, 2015.
- [2] Connor Shorten and Taghi M Khoshgoftaar. A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1):1–48, 2019.
- [3] Federal Aviation Administration. Detect and avoid (daa) concept for unmanned aircraft systems. Technical report, U.S. Department of Transportation, 2016.
- [4] Bruce T Clough. Unmanned aerial vehicles: Autonomous control challenges, a researcher's perspective. *Journal of Aerospace Computing, Information, and Communication*, 2(8):327–347, 2002.
- [5] Mariusz Bojarski, Davide Del Testa, Daniel Dworakowski, et al. End to end learning for self-driving cars. *arXiv preprint arXiv:1604.07316*, 2016.
- [6] Josh Tobin, Rachel Fong, Alex Ray, Jonas Schneider, Wojciech Zaremba, and Pieter Abbeel. Domain randomization for transferring deep neural networks from simulation to the real world. In *Robotics: Science and Systems*, 2017.
- [7] Shital Shah, Debadepta Dey, Chris Lovett, and Ashish Kapoor. Airsim: High-fidelity visual and physical simulation for autonomous vehicles. *Field and Service Robotics*, 2018.
- [8] David Čapek, Jan Hrnčíř, Tomáš Báča, Jakub Jirka, Vojtěch Vonásek, Robert Pěnička, and Martin Saska. Flightforge: Advancing uav research with procedural generation of high-fidelity simulation and integrated autonomy, 2025.
- [9] Antonella Barisic, Frano Petric, and Stjepan Bogdan. Sim2air – synthetic aerial dataset for uav monitoring. *IEEE Robotics and Automation Letters*, 7(2):3757–3764, apr 2022.
- [10] Deepak Prasad, S. Adhithyan, Kondru Thanmai, and Gourinath Banda. Paved: A synthetic dataset for developing autonomous personal aerial vehicles. *IEEE Access*, PP:1–1, jan 2023.