

Determinação de Riscos de Sobrevoos por Visão Computacional

Rafael Marinho de Andrade*

rafael.andrade@inpe.br
Instituto Nacional de Pesquisas
Espaciais; Instituto de Estudos
Avançados

Elcio Hideiti Shiguemori

elciohs@gmail.com
Instituto Nacional de Pesquisas
Espaciais; Instituto de Estudos
Avançados

Rafael Duarte Coelho dos
Santos

rafael.santos@inpe.br
Instituto Nacional de Pesquisas
Espaciais

Abstract

In the 20th century, aviation has proven itself as one of the most important techno-social revolutions of modern human history. Now, Unmanned Aerial Systems (UAS) are on the verge of leading the next techno-social revolution, remodelling several areas and moving a global market that does not stop growing. The establishment of UAV Traffic Management (UTM) systems is necessary to make this revolution happen, and one of the main obstacles is the risks involved in UAS flight, especially in urban environments. A methodology to estimate risks on the overflown environment was carried out by the usage of convolutional neural networks on the imagery of such environments, allowing the definition of safer routes and their management on the fly. Development and experimentation processes were carried out, with promising results including a convolutional neural network for pixel-wise domain that was capable of estimate risks from satellite imagery and return overflight risks heat maps.

Palavras-chave

Aeronaves Remotamente Pilotadas, Redes Neurais Convolucionais, Gerenciamento de Tráfego de VANTs, Visão Computacional.

1 Introdução

Veículos Aéreos Não-Tripulados (VANTs), também chamados de Aeronaves Remotamente Pilotadas (ARPs) ou "drones", são uma das principais inovações tecnológicas do século XXI, impulsionando uma revolução tecno-social semelhante à proporcionada pela aviação convencional no século XX, melhorando a mobilidade e sendo essenciais em diversas áreas, como a área de defesa [1]. Com a miniaturização e popularização, os VANTs tornaram-se acessíveis às massas e são cada vez mais utilizados em áreas como logística, sensoriamento remoto, entretenimento e vigilância [2], sendo aplicados em soluções para diversos problemas concebíveis [3].

No século XX, o sucesso da aviação convencional deveu-se a um rigoroso conjunto de regras internacionais e na consolidação dos Sistemas de Gerenciamento de Tráfego Aéreo, tornando a aviação segura e eficiente [2]. Os sistemas de Gerenciamento de Tráfego de VANTs (UTM – do inglês "UAV Traffic Management") ainda estão em desenvolvimento e testes, acometidos por uma série de complicações uma vez que os VANTs possuem características de voo distintas das aeronaves convencionais, a começar pelo fato de que são considerados principalmente para operação em ambientes urbanos e interurbanos, caracterizados por alto dinamismo e riscos inerentes [4].

É uma premissa comum que os VANTs modernos possuam sensores imageadores que, além de cumprir funções como a captura de dados para entretenimento e pesquisa, podem auxiliar no controle

e navegação da aeronave [5]. Esses sensores podem apoiar o piloto humano durante a operação do voo e/ou fornecer informações para sistemas autônomos, enquanto dados externos, como imagens de satélite, podem complementar as informações operacionais.

Neste trabalho foi explorada a hipótese do uso dos dados de imageamento por satélite e/ou extraídos pelos VANTs em tempo de voo para a estimação de riscos associados aos ambientes por eles sobrevoados, fazendo uso de técnicas de visão computacional baseadas em redes neurais convolucionais (CNN) para atingir tal objetivo.

2 Material e métodos

A metodologia consiste em seis etapas: 1) aquisição dos dados e pré-processamento, 2) definição dos atributos relevantes e suas ponderações, 3) geração das máscaras de treinamento, 4) modelagem da CNN, 5) treinamento da CNN, e 6) ativação da CNN com imagens aéreas para estimação de risco de sobrevoos em tempo real. Essas etapas estão representadas graficamente na Figura 1 e serão escrutinadas ao longo desta seção.

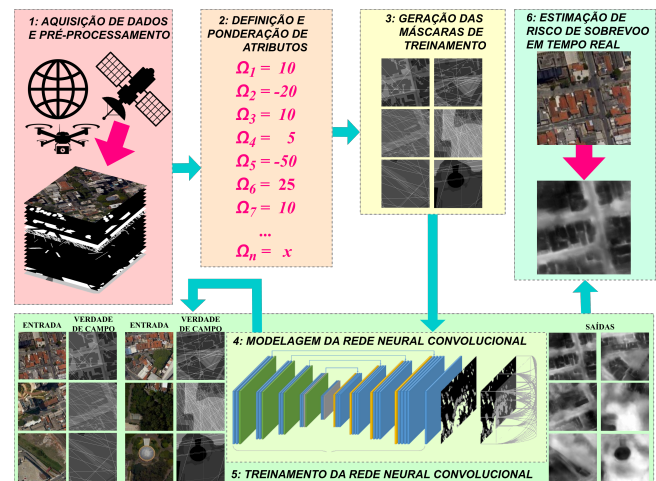


Figura 1: Processo metodológico aplicado no trabalho.

2.1 Aquisição de dados e pré-processamento

A metodologia utiliza dois tipos de dados geoespaciais: imagens aéreas, capturadas em perspectiva nadir, e máscaras de atributos, que contêm informações sobre atributos relevantes no ambiente observado. Cada legislação define regras de distância mínima e proibições de sobrevoos com base em atributos que podem ser estáticos ou dinâmicos, definidos fisicamente ou logicamente, e dependentes

ou não de condições paralelas [6]. Atributos fisicamente definidos (como prédios, rodovias, vegetação e corpos d'água) são mais seguros para classificação, pois são perceptíveis em imagens, enquanto atributos logicamente definidos (como instituições de saúde, ensino e defesa) podem ser mais difíceis de identificar.

Os atributos são representados como dados geoespaciais, com informações de latitude, longitude e intensidade de classe, que pode ser binária (presença ou ausência), contínua (valores precisos) ou discreta (classificações arbitrárias). Por exemplo, a presença de árvores é um atributo binário, enquanto a altura de edifícios é um atributo contínuo; classificações de densidade demográfica podem ser uma classificação discreta. A delimitação precisa é importante para estruturas bem definidas, enquanto áreas de exclusão são necessárias em locais críticos.

A metodologia abrange dados de diferentes origens, em especial imagens de satélites e extraídas de VANTs. As imagens de satélite oferecem resolução adequada, mas podem não ser em tempo real, enquanto as filmagens de aeronaves estão sempre atualizadas e podem ser processadas a bordo. As máscaras de atributos indicam a presença de características como edifícios e vegetação, sendo obtidas através de técnicas de processamento de imagem ou pesquisa de dados geográficos. Esses dados devem ser ortorretificados e formatados para corresponder diretamente às suas contrapartes no espectro visível.

É importante considerar também que, por se tratar de imageamento geoespacial, esses dados ficam sujeitos às condições e adversidades visuais que acometem os sensores durante a captura, das quais se destacam a meteorologia (luminosidade, reflectância e visibilidade) e iluminação (posição do sol) [4]. Essas adversidades têm potencial tanto de atrapalhar o sistema quanto torná-lo mais robusto.

A área escolhida para a experimentação foi o centro da cidade de São Paulo, Brasil, com cerca de 112 km². A cidade foi escolhida por ser uma metrópole cosmopolita, caracterizada por um ambiente urbano denso e significativa desigualdade social, o que torna o conjunto de dados mais diversificado. Para aplicar a metodologia proposta, foram coletados diversos tipos de dados, especialmente dados geoespaciais, como imagens e atributos, geralmente fornecidos por entidades governamentais para transparência, apoio a políticas públicas e pesquisa científica. Dados de imagens de alta resolução espacial também podem ser obtidos de portais como o Google Earth Engine, utilizando satélites como o LANDSAT-8, e foram também utilizados dados das seguintes fontes: 1) Geosampa [7], 2) Observatório Nacional de Transporte e Logística (ONTL) [8], 3) Agência Nacional de Águas (ANA) [9], e 4) Instituto de Controle do Espaço Aéreo (ICEA) [10].

Após reunidos, os dados foram carregados no QGIS [11] nas projeções adequadas e, mediante um processo de limpeza e eliminação de excessos da área de experimentação, os atributos foram estratificados. Processos iniciais incluíram também a fusão de camadas por contexto, como a combinação de camadas de arborização de estradas, vegetação, corredores ecológicos e reservas da Mata Atlântica em um único grupo.

Os dados históricos de voos do ICEA foram transformados em vetores, onde cada linha representa o histórico de uma diferente aeronave, classificados em voos de alta altitude (aeronaves convencionais em altitude de cruzeiro), média altitude (helicópteros locais)

e voos sem padrão definido (presumivelmente durante decolagens ou aterrissagens).

Após a organização dos dados no mapa do QGIS, foi necessário dilatá-los para incluir uma margem de segurança representativa em relação aos riscos associados. Essa dilatação considera uma margem de segurança a partir do epicentro dos objetos (radial para atributos definidos como pontos), da linha (para atributos vetoriais) ou de margens (para áreas); a margem de segurança empregada a cada atributo, definidos para efeitos de experimentação, está disposta na Tabela 1.

Tabela 1: Margem de segurança aplicada em torno dos atributos relevantes.

Atributo	Geometria	Margem
Aeródromos	Pontos	1500 m
Aeropostos	Pontos	1500 m
Arborização viária	Pontos	5 m
Áreas verdes	Áreas	Área interna
Classificação viária	Vetores	5 m
Densidade demográfica	Áreas	Área interna
Edificações	Áreas	5 m
Ferrovias	Vetores	10 m
Históricos de voo	Pontos	5 m
Instituições de educação	Pontos	150 m
Instituições de saúde	Pontos	150 m
Linhas de alta tensão	Vetores	50 m
Quadras viárias	Áreas	Área interna
Rampas de helipontos	Áreas	50 m
Rede cicloviária	Vetores	10 m
Reservas de Mata Atlântica	Áreas	5 m
Torres de alta tensão	Vetores	50 m

Após a vetorização e dilatação de todos os atributos, eles foram rasterizados em camadas individuais, de modo a permitir a extração de máscaras de atributos.

Os dados utilizados não precisaram de nenhuma operação de transformação, ortorretificação ou correção de projeção ou perspectiva.

2.2 Definição e ponderação de atributos

O índice de atributos é uma ponderação de atributos baseada em regras matemáticas, a fim de indicar quais posições geográficas são mais seguras ou arriscadas para sobrevoo. Segue o mesmo princípio de um índice espectral, utilizando máscaras de atributos em vez de bandas espectrais, onde cada pixel das máscaras corresponde às mesmas coordenadas sobrepostas como camadas de uma imagem.

Esse índice pondera cada atributo de um pixel geoespacial para criar uma máscara com valores contínuos, como um mapa de calor que mostra os riscos de sobrevoo em cada local. A presença de atributos de risco aumenta a classificação de risco dos pixels, enquanto atributos de segurança a diminuem, e a influência de cada atributo é definida pela variável Ω .

Bem como diferentes índices espectrais realçam características específicas distintas, abordagens matemáticas variadas podem ser

aplicadas aos índices de atributos para atribuir mais ou menos risco a diferentes aspectos, dependendo do contexto. Uma vez que cada legislação tem seus próprios critérios para regras de voo de VANTs [4, 6], não existe uma única abordagem matemática aplicável a todos os espaços aéreos. Portanto, a abordagem do índice de atributos é versátil, permitindo a definição e adaptação de várias fórmulas para fornecer a estimativa de risco mais adequada para cada legislação.

As máscaras de atributos são definidas como

$$A = \{M | M \in I\}, \quad (1)$$

onde A é a máscara de atributos e M é a matriz da máscara propriamente dita, que por sua vez é uma imagem I (uma matriz bidimensional onde cada valor é um pixel).

Uma vez com todos os atributos rasterizados, é possível extrair máscaras de atributos. 420 coordenadas diferentes foram definidas na área de experimentação e, a partir dessas coordenadas, foram gerados vetores quadrados medindo 40 km², com as coordenadas como epicentros, tanto em imagens do espectro visível do satélite LANDSAT-8 quanto nas 17 classes de atributos consideradas e apresentadas na Tabela 1; cada um desses quadrados representa a área de cada recorte para a geração das máscaras. Em seguida, os dados geoespaciais delimitados pelos recortes foram organizados como um cubo de dados, onde cada camada do recorte corresponde a um de seus atributos; a Figura 2 mostra uma representação deste cubo de dados.




Figura 2: Abstração dos dados geoespaciais como cubo de dados, evidenciando cada atributo como uma de suas camadas.

Cada camada de atributo consiste em uma máscara binária que indica a presença e/ou proximidade do respectivo atributo, conforme detalhado na Tabela 1, exceto pela camada de densidade demográfica; esta foi discretizada em cinco escalas diferentes. A Figura 3 dispõe algumas dessas camadas de um mesmo recorte, e a Tabela 2 sumariza os valores de influência dos atributos e seus respectivos alcances de influência, arbitrariamente definidos para efeitos de experimentação.

Tabela 2: Influência de cada atributo no índice de pertinência.

Atributo	Ω	Zona de influência
Aeródromos	-50	Raio de 1500 m
Aeroportos	-100	Raio de 1500 m
Arborização viária	-10	Raio de 5 m
Áreas verdes	10	Área interna
Classificação viária	-10	Margem de 5 m
Edificações	-30	Área interna + 5 m
Ferrovias	-10	Margem de 10 m
Instituições de educação	-25	Raio de 150 m
Instituições de saúde	-40	Raio de 150 m
Linhas de alta tensão	-50	Margem de 50 m
Quadras viárias	0	Área interna
Rampas de helipontos	-50	Área interna + 50 m
Rede ciclovária	-20	Margem de 10 m
Reservas de Mata Atlântica	50	Área interna + 5 m
Torres de alta tensão	-75	Raio de 50 m
Voos com altitude elevada	75	Margem de 5 m
Voos com altitude média	50	Margem de 5 m
Voos com altitude indefinida	25	Margem de 5 m
População: N/A	100	Área interna
População: ≤ 10 /ha	50	Área interna
População: 10/ha + 100/ha	0	Área interna
População: 100/ha + 1000/ha	-25	Área interna
População: > 1000 /ha	-50	Área interna

Para medir os riscos no ambiente sobrevoado, é necessário estabelecer métricas que definam onde é mais seguro e onde é mais arriscado sobrevoar. Essas métricas são determinadas com base na presença e proximidade de atributos relevantes, que exercem influência positiva ou negativa no índice, de acordo com regras matemáticas simples. Na prática, essas influências (Ω) e valores de proximidade devem ser baseados nas leis vigentes do ambiente onde o índice é aplicado, embora valores arbitrários possam ser utilizados para fins experimentais e para demonstrar o conceito do índice de atributos.

2.3 Geração das máscaras de treinamento

Uma vez definido o índice de atributos, todas as camadas de atributos do cubo de dados são combinadas em uma única máscara, onde cada pixel recebe um valor com base no índice. O resultado é uma máscara para a imagem aérea, representando um mapa de calor que indica os locais mais seguros e arriscados para sobrevoar, com valores mais altos indicando maior segurança e valores mais baixos indicando maior risco, ou vice-versa. Essa transformação consiste na aplicação da fórmula

$$I_p = \sum_{i=1}^{\#A} \frac{P_{Ai}}{\sigma} \times A_{\Omega i}, \quad (2)$$

onde I_p é o pixel da imagem inicial, P_{Ai} é o valor de sua coordenada na máscara de atributos em questão, e Ω é a influência do atributo em questão.

A cardinalidade do conjunto de atributos ($\#A$), nestes experimentos, ficou em 23, uma vez que são 23 atributos (tal como detalhado

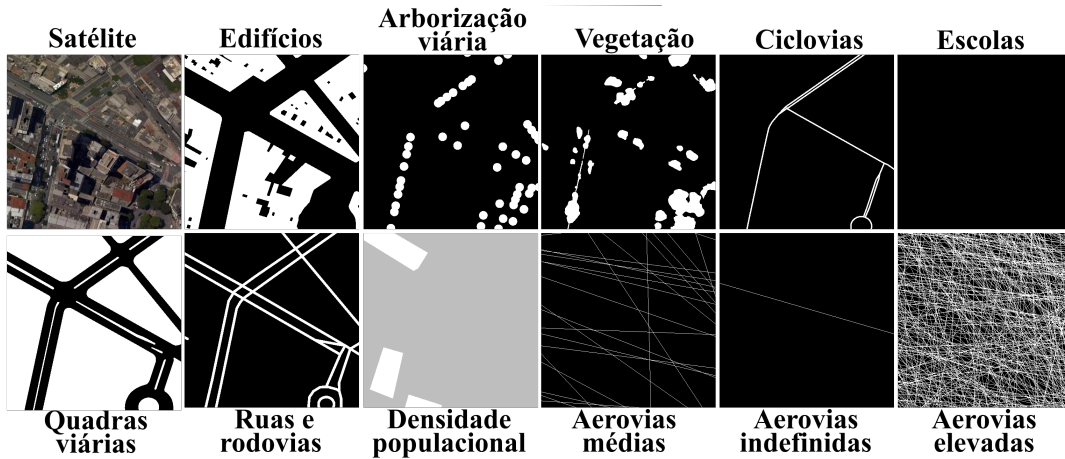


Figura 3: Disposição de algumas camadas de atributos de um mesmo espaço geográfico.

na Tabela 2; σ ficou definido como 256, uma vez que estão sendo geradas as máscaras dentro do universo matemático de 8-bits (com valores entre 0 e 255).

Com isso, então, cada pixel tem seu valor transformado à medida que é submetido aos 23 atributos presentes em sua coordenada, sendo por fim transformado para o alcance entre 0 e 255.

Após a aplicação da fórmula na Equação 2, os valores são distribuídos para compreender todo o domínio de frequência da imagem (neste caso, de 0 a 255 por se tratar de imagens de 8-bits), de modo que funcionem de forma relativa e permitam que as regiões mais seguras e perigosas para sobrevoo não sofram influência de recortes em outras regiões da área de experimentação. Essa distribuição segue a fórmula

$$I_p = \frac{\sigma}{\text{argmax}_I - \text{argmin}_I}, \quad (3)$$

onde o valor de cada pixel da imagem (I_p) é ajustado entre o argumento mínimo (argmin) e máximo (argmax) de frequência de toda a imagem (I), truncando-os entre 0 e σ .

Resultantes de todo esse processo, as máscaras de cada recorte são geradas a partir de suas camadas de atributos, o que está representado graficamente na Figura 4.

2.4 Modelagem da rede neural convolucional

A metodologia utiliza imagens aéreas como entrada para identificar riscos no ambiente observado. Uma vez que são estruturas de dados em forma de tensores, CNNs são uma abordagem adequada para a metodologia, em especial as com codificadores e decodificadores usando funções de custo de regressão linear, que geram mapas de calor com a mesma dimensionalidade da imagem de entrada.

Foram modeladas um par de arquiteturas baseadas na U-Net de Ronnenberger et al. [12], onde cada imagem aérea é inserida como entrada e sua matriz é codificada e, então, decodificada para retornar uma imagem de saída com a mesma dimensionalidade da imagem de entrada; essas arquiteturas são aqui apelidadas de redes de tipo simples e de tipo complexa, graficamente dispostas nas Figuras 5 e 6.




Figura 4: Geração das máscaras de atributos a partir das camadas que compõem os cubos de dados.




Figura 5: Diagrama da rede U-Net de tipo simples.

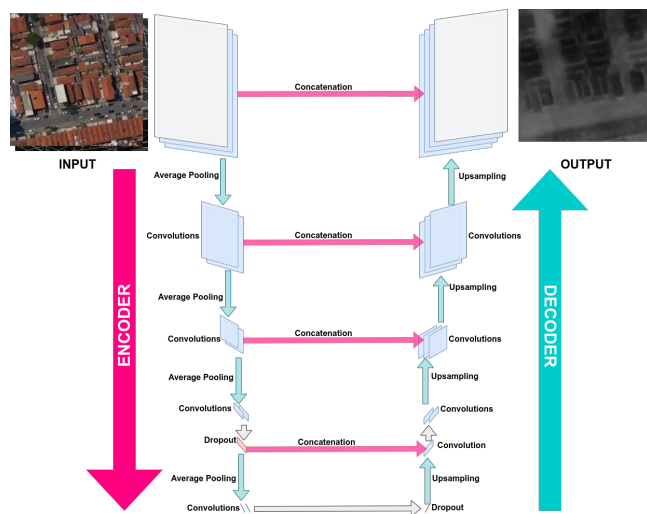


Figura 6: Diagrama da rede U-Net de tipo complexa.

Ambas as arquiteturas experimentadas utilizam unidades lineares retificadas (ReLU) ao longo de suas estruturas, com uma função identidade na saída, mantendo a frequência de saída dentro da faixa de 8 bits. A função de perda utilizada foi o erro quadrático médio (MSE), visando extrair valores matemáticos contínuos em vez de discretos (que são comuns nas arquiteturas U-Net), gerando assim mapas de calor em vez de máscaras de classificação discretas.

2.5 Treinamento da rede neural convolucional

A arquitetura U-Net é ideal para a metodologia, pois é uma CNN voltada para a classificação pixel a pixel. Neste trabalho, a U-Net foi modificada para atuar no domínio matemático contínuo, onde cada pixel recebe um valor de estimativa de risco dentro de um intervalo real, como de 0 a 100 ou de 0 a 255.

Após modelar as CNNs, seus pesos precisam ser treinados para a tarefa de estimativa de risco. Para isso, é necessário coletar um conjunto de dados de imagens aéreas com suas respectivas máscaras de treinamento, permitindo que a rede aprenda a gerar um mapa

de calor de risco de sobrevoo. O conjunto de dados deve ser representativo e equilibrado em relação a cenários reais, sem depender de condições especiais para sua formação.

No total, sete diferentes modelos foram treinados, sendo quatro do tipo complexa (C1, C2, C3 e C4) como na Figura 6 e três do tipo simples (S1, S2 e S3) como na Figura 5. Todos os modelos compilados contam com otimizador AdaM, variando as taxas de aprendizado e o número de épocas de treinamento, e aplicando um parâmetro de paciência para interromper o treinamento caso não houvesse progresso após um certo número de épocas. Além do erro quadrático médio (MSE), também foram calculados os valores do erro absoluto médio (MAE). A segmentação do conjunto de treinamento utilizou uma semente aleatória diferente em todas as sessões de treinamento, e a Tabela 3 sumariza os parâmetros aplicados em cada uma delas, bem como seus resultados; para as métricas erro médio quadrático (MSE) e erro médio absoluto (MAE), deve-se levar em consideração que os melhores valores tendem a 0.

Analisando os resultados sumarizados na Tabela 3, podemos notar que as diferentes abordagens de treinamento apresentaram valores semelhantes ao considerar a mesma arquitetura. Os parâmetros que mais influenciaram foram o tamanho do lote (quantidades maiores atingiram resultados melhores) e a taxa de aprendizado (onde a menor taxa trouxe os melhores resultados), seguido pela quantidade de épocas de treinamento.

2.6 Estimação de risco de sobrevoo em tempo real

Com a rede modelada e treinada conforme as necessidades metodológicas, ela pode ser integrada a um sistema que fornece imagens para identificar zonas de risco durante o voo. O custo computacional para ativar a rede em uma única imagem é baixo, permitindo que o sistema seja incorporado na aviônica da aeronave para realizar essa tarefa em tempo real, com uma frequência adequada ao seu deslocamento no espaço aéreo.

Além disso, a estimativa de risco pode ser realizada em um sistema centralizado e dinâmico, que mantém atualizado o mapa geral do ambiente coberto pelo UTM. Isso possibilita a geração, gestão e delegação de rotas de aeronaves com base na ativação da rede treinada, utilizando imagens de satélite ou ortomosaicos gerados pelas imagens da própria aeronave do sistema.

Tabela 3: Características de treinamento das CNNs.

Parâmetro	C1	C2	C3	C4	S1	S2	S3
Arquitetura	Complexa	Complexa	Complexa	Complexa	Simple	Simple	Simple
Semente	25324	18923	58663	53979	67707	66613	44478
Tamanho do lote	64	2	64	64	64	2	64
Taxa de aprendizado	10^{-4}	10^{-4}	10^{-5}	10^{-5}	10^{-4}	10^{-4}	10^{-5}
Limite de épocas	1000	1000	10000	10000	1000	1000	10000
Paciência	100	100	50	500	100	100	500
Épocas treinadas	465	112	117	2661	625	194	6521
MSE (aprendizado)	0.0322	0.0382	0.0167	0.0190	0.2947	0.0377	0.0290
MAE (aprendizado)	0.1437	0.1791	0.0974	0.1029	0.1388	0.1552	0.1355
MSE (validação)	0.0319	0.0381	0.0334	0.0949	0.0290	0.0380	0.0298
MAE (validação)	0.1439	0.1795	0.1419	0.2567	0.1365	0.1581	0.1377

As Figuras 7 e 8 apresentam as entradas submetidas a uma das redes e a saída resultante de seu processamento, respectivamente, para recortes isolados e para um ortomosaico da região abordada; nas imagens, tons mais claros indicam maior segurança e tons mais escuros indicam maior risco.

3 Discussão dos resultados

Para experimentar a metodologia abordada, a cidade de São Paulo foi utilizada como cenário, uma vez que os recortes utilizados no processo de treinamento compõem uma verdade de campo.

A Figura 9 compara os resultados das redes treinadas.

É possível notar algumas diferenças e padrões nos resultados, a começar pela diferença de dissolução de feições entre as duas arquiteturas: enquanto que nas redes com arquitetura simples os detalhes morfológicos da imagem ainda apresentem um certo grau de preservação, as redes com arquitetura complexa apresentaram uma maior absorção dos detalhes, preservando mais os pesos de cada região relevante. Com isso, os mapas de calor gerados pelas redes com arquitetura complexa têm maior capacidade de atribuir riscos e segurança ao longo dos ambientes observados.

Visualmente, os resultados condizem com o que foi apresentado como valores de MAE e MSE na Tabela 3, e a rede C3 apresentou os melhores resultados. A rede C4 apresentou extremização, com distribuição de valores em cauda pesada, presumivelmente por conta de *overfitting*. As redes S1, S2 e S3, que têm arquitetura simples, apresentaram pouca capacidade de distinção de riscos, ainda que não tenham chegado a se deteriorar: é notável que suas saídas mantiveram a morfologia das feições da imagem de entrada, pouco mostrando capacidade de ponderar as regiões a partir dos atributos nela presentes.

O custo computacional demandado para o treinamento das redes foi elevado, dependendo do uso do supercomputador SDumont do Laboratório Nacional de Computação Científica (LNCC) [13] para a execução de tal processo. As ativações das redes, no entanto, foram executadas em um computador doméstico de uso pessoal, indicando que a solução pode ser aplicada em tempo real em um dispositivo embarcado à aviãoica da aeronave.

4 Conclusões

É possível modelar e treinar CNNs capazes de realizar classificações pixel a pixel no domínio matemático contínuo para estimar os riscos de sobrevoar determinadas áreas, com base na presença de atributos físicos, sociais ou lógicos, como edifícios, ruas, veículos, multidões e áreas densamente povoadas. Isso pode permitir a determinação das melhores rotas para VANTs, tanto antes do voo quanto durante sua operação. Trabalhos futuros podem utilizar essa abordagem como base para modelagem ambiental qualitativa e definição de rotas no gerenciamento de tráfego aéreo, e o trabalho pode ser aprimorado ao expandir e aprofundar os passos metodológicos aqui apresentados, como a modelagem de redes mais robustas e uso de dados mais amplos. A metodologia pode ser também mais explorada com experimentações em demais localidades além do ambiente abordado, explorando a capacidade de generalização das redes em ambientes com diferentes características geográficas.

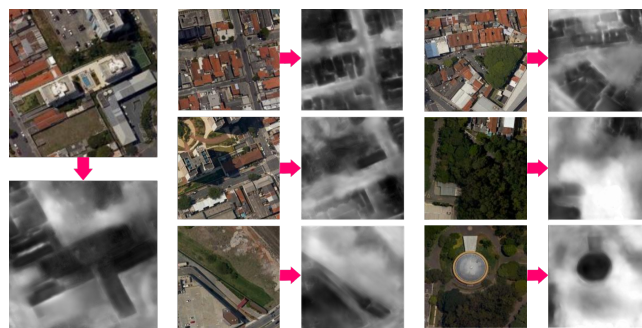


Figura 7: Exemplos de entradas e saídas da rede treinada.




Figura 8: Ortomosaico processado pela rede treinada.




Figura 9: Matriz comparando redes modeladas e treinadas.

Agradecimentos

Esse trabalho foi desenvolvido no Laboratório de Inteligência Artificial para Aplicações AeroEspaciais e Ambientais (LIAREA), integrante da Coordenação de Pesquisa Aplicada e Desenvolvimento Tecnológico (COPDT) do Instituto Nacional de Pesquisas Espaciais (INPE); os autores agradecem à Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro concedido à pesquisa em andamento através do processo de número 88887.980087/2024-00, ao Laboratório Nacional de Computação Científica (LNCC) por ceder o uso do supercomputador SDumont para treinamento das redes neurais convolucionais e processamento, através do projeto IDeepS, e ao Geosampa e Instituto de Controle do Espaço Aéreo (ICEA) pela disponibilização de dados geoespaciais essenciais para o desenvolvimento da pesquisa.

Referências

- [1] John David Blom. *Unmanned Aerial Systems*. Createspace Independent Publishing Platform, North Charleston, SC, 2010.
- [2] Thomas Prevot, Joseph Rios, Parimal H. Kopardekar, John E. Robinson III, Marcus Johnson, and Jaewoo Jung. UAS traffic management (UTM) concept of operations to safely enable low altitude flight operations. In *16th AIAA Aviation Technology, Integration, and Operations Conference*. American Institute of Aeronautics and Astronautics, June 2016. doi: 10.2514/6.2016-3292. URL <https://doi.org/10.2514/6.2016-3292>.
- [3] Justyna Jeziorska. Uas for wetland mapping and hydrological modeling. *Remote Sensing*, 11:1997, 08 2019. doi: 10.3390/rs11171997.
- [4] Aleksandar Bauranov and Jasenka Rakas. Designing airspace for urban air mobility: A review of concepts and approaches. *Progress in Aerospace Sciences*, 125: 100726, 2021. ISSN 0376-0421. doi: <https://doi.org/10.1016/j.paerosci.2021.100726>. URL <https://www.sciencedirect.com/science/article/pii/S0376042121000312>.
- [5] Parimal H. Kopardekar. Unmanned aerial system (uas) traffic management (utm): Enabling low-altitude airspace and uas operations. Technical report, NASA, 2014.
- [6] Rafael Marinho de Andrade, Elcio Hideiti Shiguemori, and Rafael Duarte Coelho dos Santos. Droneways: Definition of unmanned aircraft vehicles airways and traffic management for urban and interurban environments – a survey. In *Computational Science and Its Applications – ICCSA 2023 Workshops*, pages 179–197, Cham, 2023. Springer Nature Switzerland. ISBN 978-3-031-37114-1.
- [7] Prefeitura de São Paulo PMSP. Geosampa - mapa digital da cidade de são paulo. [S.I.], 2024. Available at: http://geosampa.prefeitura.sp.gov.br/PaginasPublicas/_SBC.aspx.
- [8] Observatório Nacional de Transporte e Logística ONTL. Dados geográficos por modos. [S.I.], 2024. Available at: <https://ontl.infrasa.gov.br/dados-geograficos-por-modos/>.
- [9] Agência Nacional de Águas e Saneamento Básico ANA. Dados abertos. [S.I.], 2024. Available at: <https://www.gov.br/ana/pt-br/aceso-a-informacao/dados-abertos>.
- [10] Instituto de Controle do Espaço Aéreo ICEA. Departamento de controle do espaço aéreo. [S.I.], 2024. Available at: <https://www.icea.decea.mil.br/>.
- [11] QGIS Development Team. Qgis geographic information system. <https://qgis.org>, 2024. Accessed: 2024-12-10.
- [12] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015. URL <http://arxiv.org/abs/1505.04597>.
- [13] Laboratório Nacional de Computação Científica (LNCC).