

## Metodologia

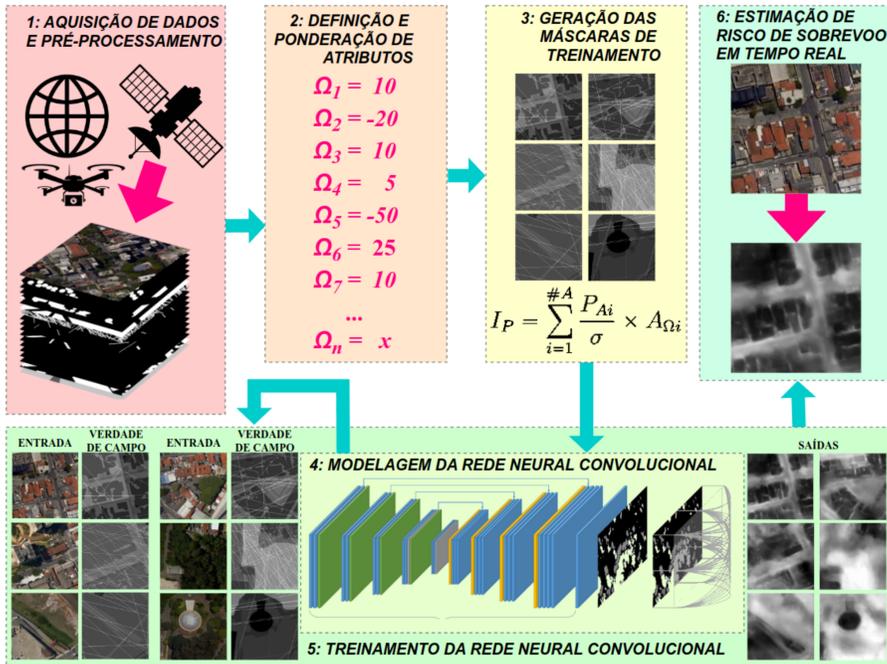


Figure 1: Metodologia aplicada no projeto, caracterizado pela aquisição de dados, definição e ponderação dos atributos e todo o processo de treinamento para a estimação de risco de sobrevoos a partir de imagens. As máscaras de treinamento são geradas a partir de um índice de atributos, onde o valor de cada pixel da máscara é influenciado pelos atributos considerados, ponderados a partir de qualquer regra concebível.

## Desenvolvimento e resultados

Para o desenvolvimento do projeto, foi delimitada como área de experimentação a região central da cidade de São Paulo. Foram utilizados dados geoespaciais publicamente fornecidos pelo portal GeoSampa, Observatório Nacional de Transporte e Logística (ONTL), Agência Nacional das Águas (ANA) e Instituto de Controle do Espaço Aéreo. Esses dados foram então processados para a geração das máscaras a partir do índice de atributos.

Atributo	Influência ( $\Omega$ )	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 heliportos	-50	Área interna + 50 m
Rede cicloviária	-20	Margem de 10 m
Reservas de Mata Atlântica	50	Área interna + 5 m
Torres de alta tensão	-75	Raio de 50 m
Linhas de voo: altitude elevada	75	Margem de 5 m
Linhas de voo: altitude média	50	Margem de 5 m
Linhas de voo: altitude indefinida	25	Margem de 5 m
População: sem população fixa	100	Área interna
População: $\leq 10$ /ha	50	Área interna
População: 10/ha $\rightarrow$ 100/ha	0	Área interna
População: 100/ha $\rightarrow$ 1000/ha	-25	Área interna
População: $> 1000$ /ha	-50	Área interna

Figure 2: Cada atributo geoespacial considerado é ponderado para exercer uma influência na inferência dos riscos de sobrevoos. Valores positivos indicam maior segurança, enquanto valores negativos indicam maior risco.

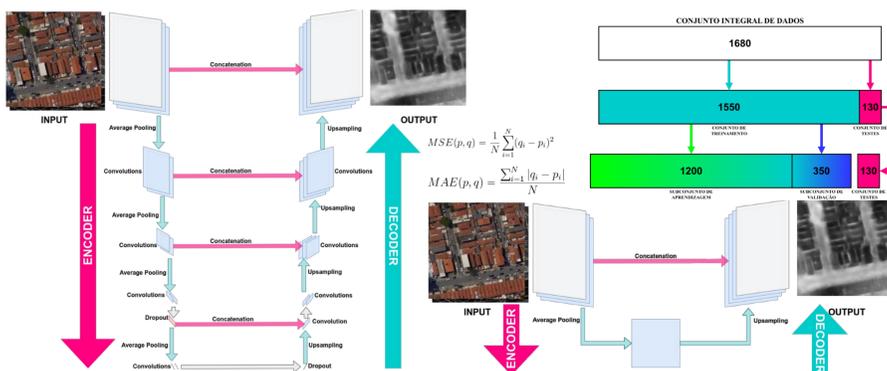


Figure 3: As redes treinadas foram baseadas na U-Net de Ronneberger [1], porém com funções de custo típicas de regressões lineares, permitindo que cada pixel da imagem de saída esteja dentro de um universo matemático contínuo, gerando mapas de calor orientados ao risco aferido pela rede. Os treinamentos foram alimentados por 1680 imagens.

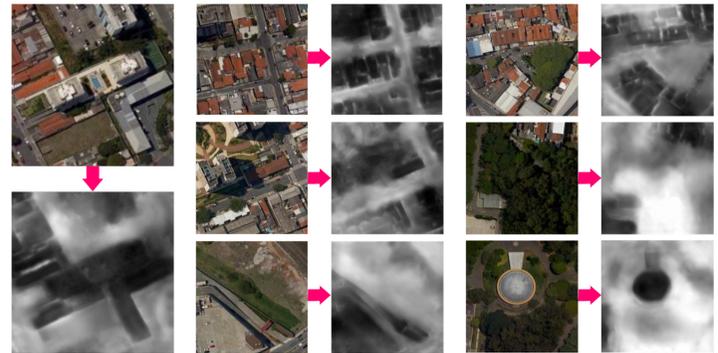


Figure 4: As redes neurais convolucionais treinadas recebem como entrada imagens aéreas (tais como de satélite ou ainda por aeronaves) e retornam como saída imagens análogas apresentando um mapa de calor acerca dos riscos aferidos.

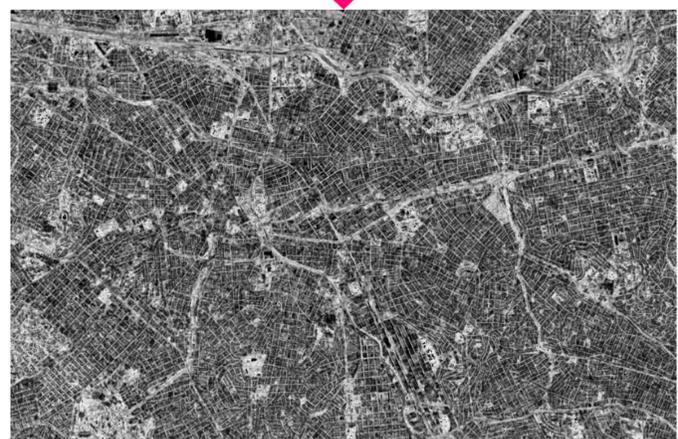
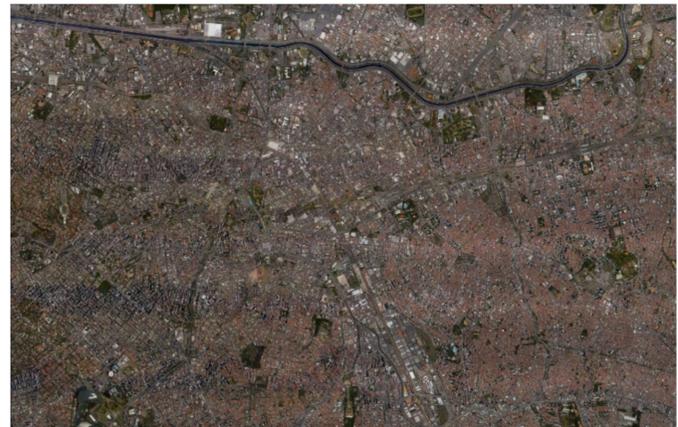
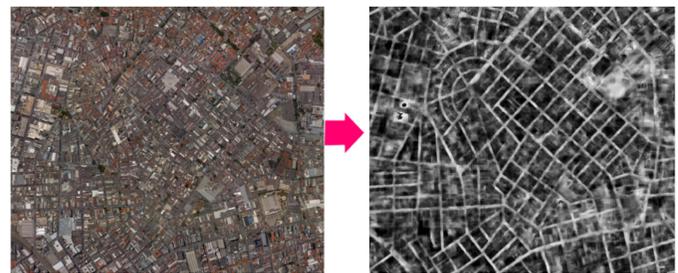


Figure 5: Ainda que as demandas computacionais sejam consideravelmente elevadas para a execução das redes, é possível executar as redes em lote e gerar ortomosaicos de regiões inteiras, como mapas de riscos.

## Conclusões

Uma vez disponíveis dados geoespaciais acerca de atributos considerados relevantes, de modo que possam ser organizadas em camadas (tal como um cubo de dados), a abordagem de definição de índice de atributos é funcional para a geração de máscaras para alimentar o treinamento de redes neurais convolucionais para processamento de imagens a nível de pixel, a fim de aferir riscos de sobrevoos. É importante observar que as redes convolucionais são sensíveis aos pesos definidos pelo índice. Isso garante à abordagem versatilidade para a aplicação em diversos ambientes e contextos, permitindo ajustar a solução para diferentes perspectivas legais e culturais.

## Agradecimentos

Os autores agradecem a Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), por fornecer financiamento para o desenvolvimento e publicação do projeto; o projeto IDeepS, apoiado pelo Laboratório Nacional de Computação Científica, que disponibilizou o uso do supercomputador SDumont, fundamental para o treinamento das redes neurais; e o Instituto de Controle do Espaço Aéreo (ICEA) e Geosampa pelo fornecimento dos dados consumidos no desenvolvimento do projeto.

## References

[1] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015.