



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

DETECÇÃO AUTOMÁTICA DE PESSOAS COM USO DE REDES NEURAS CONVOLUCIONAIS PARA APLICAÇÕES DE CÁLCULO DE TRAJETÓRIA DE DRONES

Ellen Tuane Silva Pinto

Relatório de Iniciação Científica do programa PIBIC, orientada pelos Dr. Nandamudi Lankalapalli Vijaykumar e Dr. Elcio Hideiti Shiguemori.

URL do documento original:

[<http://urlib.net/>](http://urlib.net/)

29 de setembro de 2022

RESUMO

Os drones, também conhecidos por Aeronaves Remotamente Pilotadas ou Veículos Aéreos Não Tripulados, têm sido utilizados em diversas aplicações. Entre elas, destacam-se vigilância, busca e resgate, monitoramento, entrega de mercadorias e entretenimento. No entanto, há uma grande preocupação em relação à segurança, visando a proteção à vida humana e de patrimônios, sendo evidenciado em documentos da Agência Nacional de Aviação Civil e Instituto de Controle do Espaço Aéreo. Devido ao risco de quedas e outros acidentes, a regularização atual consiste em manter uma distância mínima de 30 metros na horizontal de pessoas. Deste modo, este estudo tem como principal objetivo fazer um estudo do uso de técnicas computacionais para a detecção automática de pessoas em imagens obtidas por drones e possibilitar a emissão de alerta para evitar sobrevoá-las. Para isso, propõe-se o estudo do emprego de técnicas de inteligência artificial, em especial, as de aprendizagem de máquina. Especificamente, são utilizadas Redes Neurais Convolucionais “YOLO v4” para detecção de objetos. Então, primeiramente, duas redes “YOLO v4” e “YOLO v4 Tiny” foram treinadas e ativadas em imagens coletadas a partir de uma visada com apontamento vertical (NADIR). Em segundo, foi avaliado o desempenho das rede, sendo assim a ativação das redes treinadas apresentaram, respectivamente, *F1 Score* de 84.80% e 84.79% para voos de 10 metros de altura e *F1 Score* de 92.98% e 34.36% para voos de 25 metros de altura. Com propósito de avaliar a distância dos objetos em relação ao drone e definir a área proibida de voo, a terceira etapa consistiu em estimar a distância dos objetos a partir da imagem. Para esta tarefa foi designada a técnicas de Distância de Amostra de Solo (do inglês *Ground Sample Distance*).

Palavras-chave: Inteligência artificial. Visão Computacional. Navegação autônoma. Rede Neural Artificial. Drones.

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 Cronograma de Atividades	3
2.1 Desempenho rede YOLO v4	7
2.2 Desempenho rede YOLO v4 tiny	7
2.3 Ilustração visada NADIR	8
2.4 Flir Duo R Termal	8
2.5 DJI Matrice 600	9
2.6 Exemplo de objetos a 10 metros de altura	9
2.7 Exemplo de objetos a 25 metros de altura	10
2.8 Intersecção sobre União	11
2.9 Exemplo de Classificadores	11
2.10 Tabela Classificadores Matriz de Confusão	12
2.11 Métricas da Matriz de Confusão	13
2.12 Distância de Amostra de Solo.	14
2.13 Gráfico das Métricas Extraídas para Rede YOLO v4.	15
2.14 Gráfico das Métricas Extraídas para Rede YOLO v4.	15
2.15 Gráfico das Métricas Extraídas para Rede YOLO v4 Tiny.	16
2.16 Gráfico das Métricas Extraídas para Rede YOLO v4 Tiny.	16
2.17 Gráfico das Métricas Extraídas da Matriz Confusão para Rede YOLO v4 Tiny Redimensionada.	17
2.18 Gráfico das Métricas Extraídas da Matriz Confusão para Rede YOLO v4 Tiny.	17
2.19 Desempenho Rede YOLO v4 Tiny em imagem captada a 25 metros de altura	18
2.20 Desempenho Rede YOLO v4 Tiny redimensionada para 640 em imagem captada a 25 metros de altura	18
2.21 Estimativa de distância dos objetos detectados em imagem captada a 25 metros de altura	19

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 CRONOGRAMA DE ATIVIDADES	2
2 DESENVOLVIMENTO	5
2.1 MATERIAIS E MÉTODOS	5
2.1.1 MÉTODOS	5
2.1.1.1 APRENDIZADO DE MÁQUINA	5
2.1.1.2 REDES NEURAIAS ARTIFICIAIS	5
2.1.1.3 REDES NEURAIAS CONVOLUCIONAIS	6
2.1.1.4 REDE YOLO	6
2.1.2 EXPERIMENTO	8
2.1.3 TRATAMENTO DOS DADOS E TREINAMENTO DA REDE	9
2.1.4 AVALIAÇÃO DOS RESULTADOS	10
2.2 RESULTADOS	14
3 CONCLUSÕES	21
REFERÊNCIAS BIBLIOGRÁFICAS	23

1 INTRODUÇÃO

Os drones, nome genérico para caracterizar todo e qualquer objeto voador não tripulado, tecnicamente conhecidos por Aeronaves Remotamente Pilotadas (ARP) ou Veículos Aéreos Não Tripulados (VANT), têm sido utilizados em diversas aplicações. Entre elas, destacam-se vigilância (PARK J.; CHOI, 2019), busca e resgate (AVANZATO, 2020), monitoramento (AVANZATO R.; BERITELLI, 2020), entrega de mercadorias (FENG K.; LI, 2020) e entretenimento (EICHHORN C.; JADID, 2020).

Pode-se dizer que atualmente existem diferentes tipos de aeronaves, tais como as de asa rotativa, asa fixa e os híbridos, entre outros. Até o momento, fica claro que não existe uma única classificação sistemática de cenários de tarefas para esses aparelhos, que podem variar em tamanho, envergadura e forma. Os drones geralmente são incorporados com diversos equipamentos, tais como câmeras na faixa do visível e infravermelhas, sensores, sistema de GPS, que podem enviar os dados atualizados em tempo real para o equipamento terrestre. Alguns deles gerenciam missões totalmente autônomas com plano de voo e tempo tendo em conta a medição da asa, nível da bateria, regulamentos de voo, dados do local e por fim podem evitar obstáculos laterais baseados em modelos de inteligência artificial. (MITKA1 E.; MOUROUTSOS, 2017)

No entanto, á medida em que houve aumento nas aplicabilidades de drones, problemas de segurança também aumentaram, como por exemplo colidir com pessoas ao perder o controle ou invadir propriedades. Por esse motivo, há uma grande preocupação em relação à segurança, visando-se proteção à vida humana e patrimônios sendo evidenciadas internacionalmente (STÖCKER C.; BENNETT, 2017) em também nacionalmente, como em documentos da Agência Nacional de Aviação Civil (ANAC, 2017) e Departamento de Controle do Espaço Aéreo (DECEA, 2018), na qual uma delas consiste em que a distância da aeronave não tripulada não poderá ser inferior a 30 metros horizontais de pessoas não envolvidas e não anuentes com a operação.

Porém, tem sido observados descumprimentos desta determinação (NEVES, 2019), sendo assim, vislumbra-se o uso de sistemas automatizados para evitar esta ação. Recentemente a aplicação de técnicas de visão computacional para veículos autônomos vem apresentando excelentes resultados, um exemplo disso é evidenciado em trabalhos como (LI et al., 2020), na qual baseado em visão computacional, avaliou o desempenho para detectar e identificar vários objetos e prever a intenção de mo-

vimento do pedestre na cena. A principal contribuições desta pesquisa foi criar um modelo otimizado capaz de detectar 10 tipos de objetos baseados na estrutura do YOLO v4.

Com isso, este estudo de iniciação científica tem como principal objetivo fazer uso de técnicas computacionais para a detecção automática de pessoas em imagens obtidas por drones. Como objetivos específicos, este projeto pretende propor métodos para detectar e evitar sobrevoar pessoas. Para isso, propõe-se o emprego de técnicas de inteligência artificial, em especial, as de aprendizagem de máquina. Serão utilizadas Redes Neurais Convolucionais para detecção de objetos, como a rede YoloV4 (REDMON J.; DIVVALA, 2016).

1.1 CRONOGRAMA DE ATIVIDADES

Assim como disposto no “formulário de proposta de bolsa PIBIC”, as atividades previstas para atingir os objetivos do projeto são descritas a seguir:

- a) Estudo e planejamento para captura de imagens com uso de drones;
- b) Estudo de técnicas de aprendizagem de máquina;
- c) Estudo de Redes Neurais Convolucionais, em especial a Yolo;
- d) Acompanhamento dos voos para captura das imagens e vídeos;
- e) Preparação dos dados de treinamento e rotulagem dos dados;
- f) Treinamento da Rede Neural Convolucional;
- g) Realização de testes em laboratório do emprego da Rede Neural Convolucional com imagens obtidas pelos Drones;
- h) Elaboração do relatório;
- i) Estudo de sistemas embarcados, como Raspberry Pi e Odroid;
- j) Avaliação da implementação da ativação da Rede Neural Convolucional em sistemas embarcados para aplicação em tempo real;
- k) Elaboração do relatório final.

Conforme atividades listadas acima, o cronograma desse projeto de pesquisa de iniciação científica é apresentado na Figuras 1.1. Na qual cada coluna corresponde a um mês, tendo como período total correspondente a um ano.

Figura 1.1 - Cronograma de Atividades

Atividade	Mês											
	1	2	3	4	5	6	7	8	9	10	11	12
a	X											
b		X										
c		X	X									
d			X									
e				X								
f					X	X						
g						X	X					
h							X					
i								X	X			
j									X	X	X	
k											X	X

Fonte: Produção do autor.

2 DESENVOLVIMENTO

Este capítulo aborda as características gerais das tecnologias e descrição da metodologia aplicadas no desenvolvimento do projeto. Finalizando, é realizada a descrição dos dados coletados pelos experimentos, como também a análise dos mesmos.

2.1 MATERIAIS E MÉTODOS

Esta seção contempla a descrição da metodologia adotada para o desenvolvimento do trabalho, das técnicas e processos empregados, bem como do delineamento experimental. Sendo dividida em organização dos dados e treinamento da rede e testes de desempenho.

2.1.1 MÉTODOS

2.1.1.1 APRENDIZADO DE MÁQUINA

Aprendizado de Máquina (do inglês, *machine learning*) é um sub campo da inteligência artificial. Resumidamente, é um método baseado em modelos matemáticos combinado com processamento computacional para detectar e analisar padrões por meio de dados e se adaptar a partir disso. Atualmente existem, três tipos de aprendizado de máquina, sendo eles o aprendizado supervisionado, não supervisionados e aprendizagem por reforço. A principal diferença entre os dois primeiros tipos é que para a aprendizagem supervisionada faz-se necessário o uso de intervenção humana, neste caso os dados devem ser categorizados manualmente. Na aprendizagem supervisionada, o objetivo então é encontrar uma relação entre a entrada e saída de dados. Por outro lado, a aprendizagem não supervisionada baseia-se em descobrir padrões escondidos no conjunto de dados. Ao que se refere a aprendizagem por reforço, pode-se dizer que é uma tarefa de aprendizado em que a máquina decide qual o próximo passo baseado em tentativa e erro, sendo usados os retornos de suas próprias ações. O modelo utilizado neste trabalho pode ser categorizado como aprendizado supervisionado, visto que de modo a ensinar o algoritmo, os objetos contidos nas imagens do conjunto de dados de treinamento são etiquetado e categorizados por classes.

2.1.1.2 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA) são modelos matemáticos de aprendizagem que tem sua arquitetura baseado em rede de neurônios biológicos. O neurônio, aqui chamado de perceptron, é uma junção das funções de regressão linear e logística. A função linear neste caso é encarregada de determinar a relação entre os atributos e a

classificação desejada e a logística determinará a partir do resultado da função linear qual a classificação correta. Resumidamente, cada neurônio recebe como entrada as características dos problemas, sendo essas multiplicadas pelo seu respectivo peso e o somador realiza o processamento, que é a soma das multiplicações das entradas vezes o peso. A função de ativação é responsável por ativar ou inibir a intensidade do neurônio que serve como o resultado na saída. Partindo disso, uma rede seria a junção de vários neurônios na qual cada neurônio seria responsável por detectar um atributo. Por fim, esses modelos são ideais para lidar com grandes volumes de dados, em especial com imagens, sendo treinadas com o objetivo de performar uma tarefa.

2.1.1.3 REDES NEURAIAS CONVOLUCIONAIS

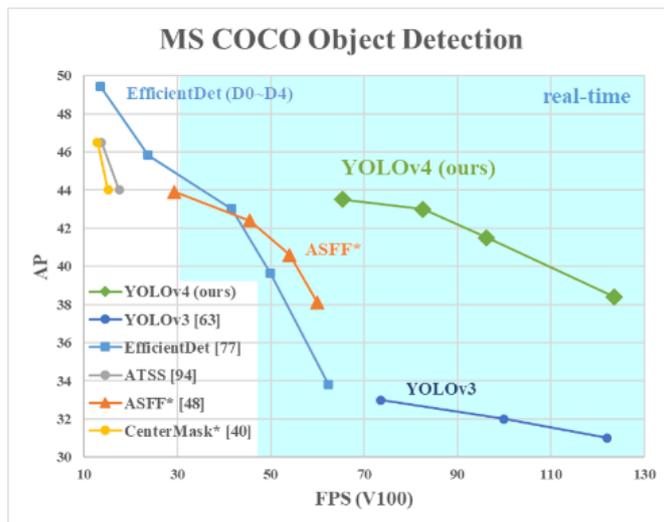
Entre as redes neurais artificiais, existem diferentes tipos com aplicações também distintas. Redes neurais convolucionais (RNC) são redes que possuem a aplicações de filtros capazes de mapear e detectar atributos antes das entradas de redes neurais. O filtro, que também é conhecido por kernel, é formado por pesos inicializados aleatoriamente, atualizando-os a cada nova entrada durante o processo de *backpropagation*. Esse tipo de rede é adequada para trabalhar com imagens, sendo capaz de atingir alto desempenho em tarefas visuais complexas. Alguns cenários em que se pode aplicar essas redes são: reconhecimento e detecção de elementos em imagens e descrição de uma imagem.

2.1.1.4 REDE YOLO

A detecção de objetos em imagens é uma das aplicações de aprendizado de máquina que tem evoluído bastante nos últimos anos. Em modelos mais antigos de detecção de objetos era necessário que o algoritmo analisasse de forma separada diversas partes de uma imagem, na tentativa de encontrar objetos conhecidos e colocar um retângulo sinalizando onde eles estavam, no caso do YOLO, o algoritmo olha apenas uma vez para a imagem, dividindo-a em diversos retângulos e inferindo onde estão os objetos através de probabilidade. Os retângulos que possuem uma probabilidade acima de um determinado limite de existir um objeto conhecido ali, são selecionados.

Na Figura 2.1 há uma comparação da YOLO v4 proposto e outros detectores de objetos de última geração. É possível notar que a YOLO v4 é executado duas vezes mais rápido que o EfficientDet com desempenho comparável. Melhora Average Precision e FPS do YOLOv3 em 10% e 12%, respectivamente.

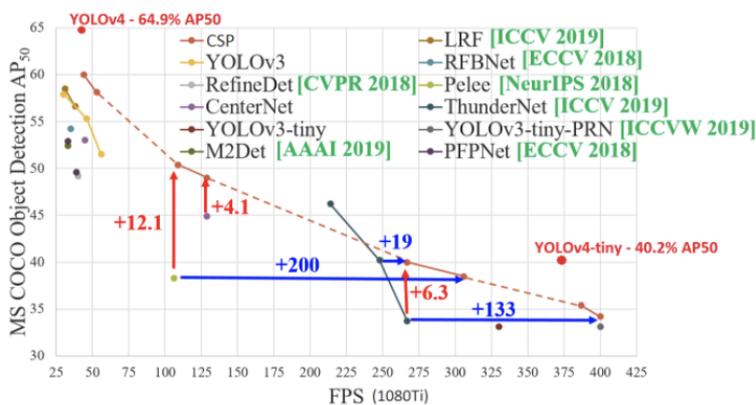
Figura 2.1 - Desempenho rede YOLO v4



Fonte: YOLOv4: Optimal Speed and Accuracy of Object Detection, 2020.

Ao que se refere ao modelo YOLO v4 tiny, conforme Figura 2.2 a rede atinge 42,0% AP50, a uma velocidade de 443 FPS. Portanto, para detecção de objetos em tempo real, o YOLO v4 tiny é a melhor opção quando comparado ao YOLO v4, pois o tempo de inferência mais rápido é mais importante do que a precisão ou exatidão ao trabalhar com um ambiente de detecção de objetos em tempo real.

Figura 2.2 - Desempenho rede YOLO v4 tiny

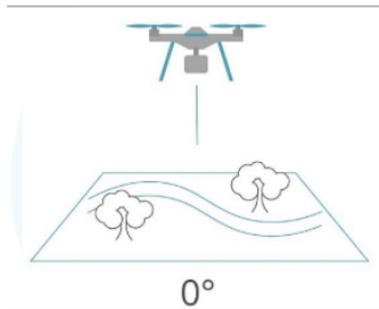


Fonte: YOLOv4: Optimal Speed and Accuracy of Object Detection, 2020.

2.1.2 EXPERIMENTO

As imagens utilizadas para treinar e testar o desempenho da rede foram captadas a partir de visada NADIR, ilustrada na Figura 2.3, pela câmera Flir Duo R Termal, Figura 2.5, na qual foram utilizadas apenas as imagens captadas pelo sensor na faixa do visível. Os voos foram realizados pelo Drone modelo DJI Matrice 600, representado na Figura 2.4, com altitudes de 10 e 20 metros.

Figura 2.3 - Ilustração visada NADIR



Fonte: Fonte: AECSce (adaptado), 2022.

Figura 2.4 - Flir Duo R Termal



Fonte: Fonte: Flir Cameras, 2022.

Figura 2.5 - DJI Matrice 600

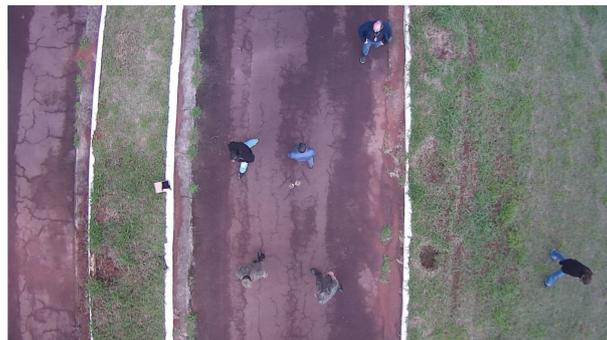


Fonte: Fonte: DJI, 2022.

2.1.3 TRATAMENTO DOS DADOS E TREINAMENTO DA REDE

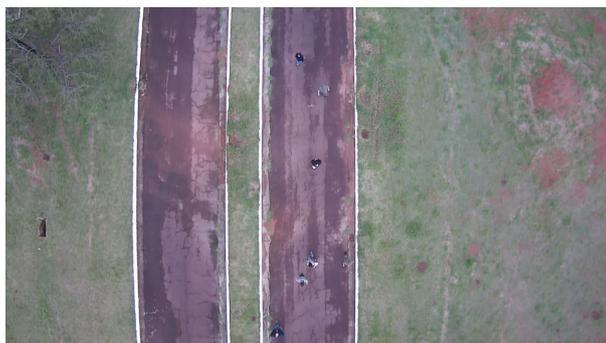
Primeiramente foi realizado o tratamento dos dados, na qual foram separado em conjuntos de treinamento, validação e teste. Para o treinamento então, foram utilizadas 400 imagens contemplando variadas alturas de voo, das quais 280 constituíram o conjunto de treinamento e 120 o conjunto de validação. Já para o conjunto de testes, foram separadas 120 imagens a 10 metros de altura, exemplificado na Figura 2.6 e 60 imagens a 25 metros de altura, Figura 2.7.

Figura 2.6 - Exemplo de objetos a 10 metros de altura



Fonte: Produção do autor.

Figura 2.7 - Exemplo de objetos a 25 metros de altura



Fonte: Produção do autor.

Para que a rede identifique os objetos nas imagens e assim aprenda as características e padrões dos objetos, no segundo passo foi utilizado o software LabelImg para etiquetar os objetos presentes nas imagens, gerando assim um arquivo que contempla as classes dos objetos e respectivas coordenadas de posição nas imagens.

A terceira etapa constituiu em treinar a rede YOLO v4, para isso foi utilizado o ambiente Google Colab, framework Darknet e linguagem de programação Python.

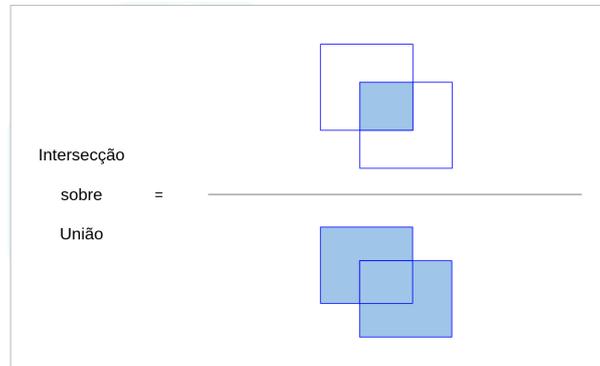
2.1.4 AVALIAÇÃO DOS RESULTADOS

Para avaliação dos resultados de detecção da rede YOLO, serão considerados as métricas de intersecção sobre união e matriz de confusão. Quanto a estimativa de distância do objeto, foi utilizado a técnica de distância de Amostra do Solo. Todos abordadas detalhadamente a seguir.

Intersecção sobre União (IoU) é uma métrica de avaliação usada para medir a precisão de um detector de objetos em um conjunto de dados específico. Algoritmos que fornecem caixas delimitadoras (do inglês *bounding boxes*) previstas como saída pode ser avaliada usando IoU. Mais especificamente, para utilizar IoU como avaliar um detector de objetos precisamos das caixas delimitadoras de verdade, ou seja, as caixas delimitadoras rotuladas à mão do conjunto de teste que especificam onde na imagem o objeto está e das caixas delimitadoras previstas do nosso modelo. O cálculo da IoU pode, portanto, ser determinado conforme Figura 2.8, na qual no numerador, calcula-se a área de sobreposição entre a caixa delimitadora prevista pelo modelo e a caixa delimitadora verdadeira. O denominador é a área de união, ou mais simplesmente, a área abrangida pela caixa delimitadora prevista e pela caixa

delimitadora verdadeira. Então ao dividir a área de sobreposição pela área de união resulta no valor de IoU.

Figura 2.8 - Intersecção sobre União



Fonte: Produção do autor.

Um exemplo de como os classificadores se comportam no conjunto de dados deste trabalho é exemplificado na Figura 2.9, na qual as caixas delimitadoras de verdade estão representadas em amarelo, as caixas delimitadoras de predita em verde são os verdadeiro positivos, as em azul os falsos positivos e por fim, as vermelhas são o falso negativo.

Figura 2.9 - Exemplo de Classificadores



Fonte: Produção do autor.

A matriz de confusão, por sua vez, é uma tabela que permite extrair métricas que auxiliam na avaliação de modelos de aprendizado de máquina para classificação quando a variável resposta é categórica, ou seja, também aplicável nos modelos de detecção de objetos, pois classificam os objetos em diferentes a classes. Os três classificadores da matriz de confusão são normalmente: Os verdadeiros positivos, que são os objetos detectados e classificados corretamente; Os falso positivos, objetos detectados, mas classificados incorretamente; E os falsos negativos objetos que não foram detectado pelo modelo. Importante ressaltar que os verdadeiros negativos não se aplicam a detecção de objetos. ver Figura 2.10.

Figura 2.10 - Tabela Classificadores Matriz de Confusão

		Detectado	
		Verdadeiro	Falso
Amostra	Verdadeiro	Verdadeiro Positivo	Falso Negativo
	Falso	Falso Positivo	Verdadeiro Negativo

Fonte: Produção do autor.

A partir dos classificadores da matriz de confusão, são extraídos quatro métricas que possibilitam avaliar de fato o desempenho do modelo. Uma delas é a *Acuracy*, que determina dentre todas as detecções possíveis, quantas o modelo classificou corretamente. A segunda é o *Recall*, trás a proporção entre os verdadeiros positivos e falsos negativo, ou seja, dentre todas as situações de detecção esperada, quantas estão corretas. A terceira métrica é a *Precision*, que olha apenas para o percentual de preditos positivos corretos dentro de todos casos preditos como positivos pelo modelo. Por fim, o *F1 Score* é um balanço entre o *Precision* e o *Recall*. As formulas de cada métrica podem ser consultada na Figura 2.11.

Figura 2.11 - Métricas da Matriz de Confusão

$$\begin{aligned} \textit{Acurácia} &= \frac{VP}{VP + FP + FN} & \textit{Precisão} &= \frac{VP}{VP + FP} \\ \textit{Recall} &= \frac{VP}{VP + FN} & \textit{F1 Score} &= 2 \frac{\textit{Precisão} \times \textit{Recall}}{\textit{Precisão} + \textit{Recall}} \end{aligned}$$

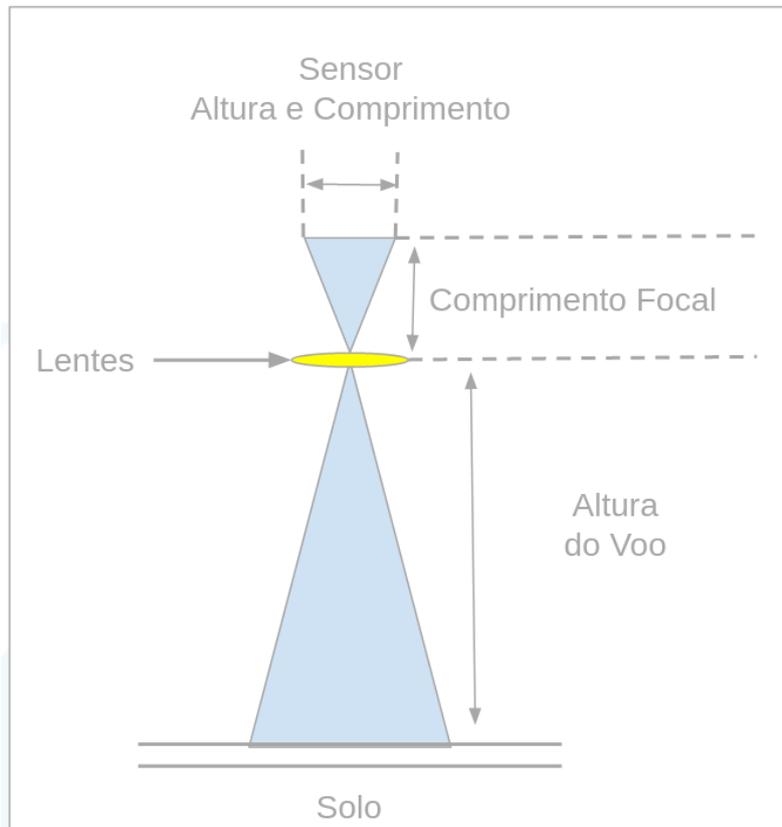
Fonte: Produção do autor.

Para avaliação do modelo de detecção proposto por este projeto, é importante evidenciar que a acurácia, possui limitações, como por exemplo, a possibilidade de enviesar o entendimento quando as classes da variável resposta não são balanceadas. Deste modo, para avaliação de desempenho da rede é sugerido que seja avaliado o resultado da métrica *F1 Score*.

Portanto, partindo dos conceitos apresentados de IoU e matriz de confusão, utilizou-se o cálculo de IoU para determinar os classificadores da matriz de confusão, extraindo, por fim, as métricas para avaliação de desempenho para o modelo de detecção de objetos deste trabalho.

Para estimativa de distância do drone em relação ao objeto, foi aplicado a técnica de distância de amostragem do solo (do inglês *Ground Sample Distance*). Esquematizada na Figura 2.12, essa métrica é útil para fotogrametria e medições em projetos de mapeamento e levantamento de drones. O GSD é definido como a distância entre os centros de dois pixels adjacentes medidos no solo. Essa métrica está relacionada à distância focal da câmera, à resolução do sensor da câmera e à distância da câmera em relação ao solo. Esta etapa é importante para verificar se a visada utilizada no experimento junto com a altura de voo são eficazes para solucionar o problema proposto.

Figura 2.12 - Distância de Amostra de Solo.



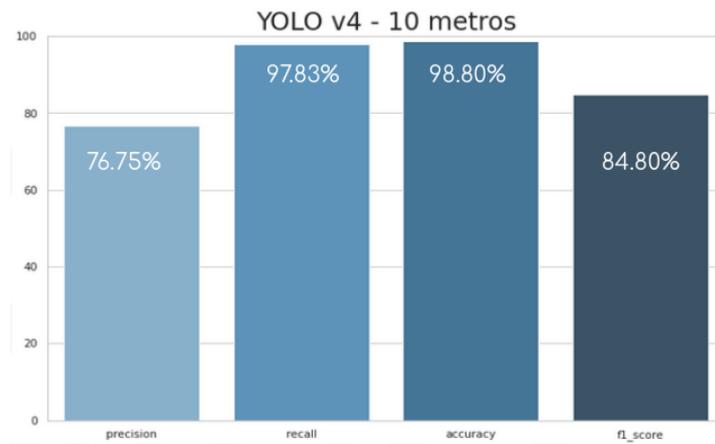
Fonte: Produção do autor.

2.2 RESULTADOS

Para demonstrar os resultados foram gerados gráficos das médias de *Precision*, *Recall*, *Acuracy* e *F1 Score* para as ativações das redes YOLO v4 e YOLO v4 Tiny nos conjuntos de dados dos voos de 10 e 25 metros de altura. Importante ressaltar que para análise dos resultados de desempenho das redes, será analisado em especial a métrica *F1 Score*, visto que esta é uma balanço entre o *Recall* e *Precision*.

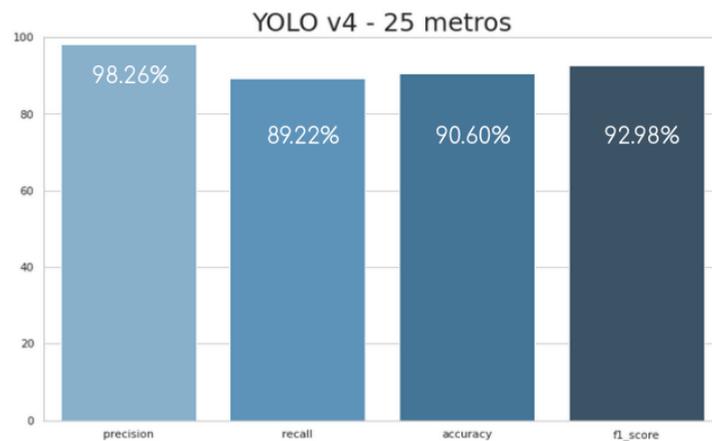
Deste modo, ao ativar a rede YOLO v4 nos conjuntos de dados é possível observar nos gráficos da Figura 2.13 e Figura 2.14 que a rede apresenta respectivamente 84.80% para objetos a 10 metros de altura e 92.98% de *F1 Score* para objetos a 25 metros de altura.

Figura 2.13 - Gráfico das Métricas Extraídas para Rede YOLO v4.



Fonte: Produção do autor.

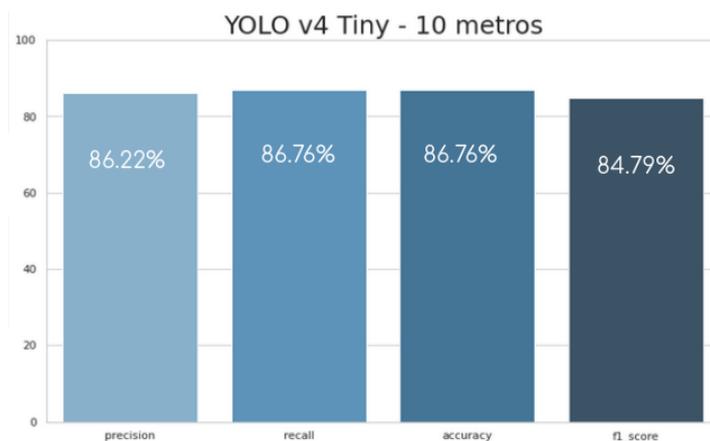
Figura 2.14 - Gráfico das Métricas Extraídas para Rede YOLO v4.



Fonte: Produção do autor.

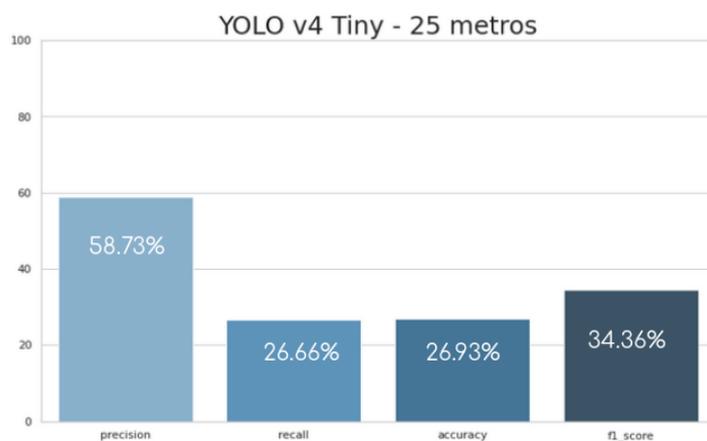
A ativação da rede YOLO v4 Tiny, por sua vez, apresenta 84.79% de *F1 Score* para o conjunto de imagens do voo de 10 metros de altura, enquanto que para o outro conjunto de imagens, a mesma rede apresenta um resultado de *F1 Score* baixo, 34.36%. Considerando as características da YOLO v4 Tiny, na qual há uma queda no desempenho de modo a aumentar a velocidade de detecção e que os objetos a 25 metros de altura são menores, o resultado de 34.36% é justificável. Os dados podem ser observados nas Figuras 2.15 e 2.16.

Figura 2.15 - Gráfico das Métricas Extraídas para Rede YOLO v4 Tiny.



Fonte: Produção do autor.

Figura 2.16 - Gráfico das Métricas Extraídas para Rede YOLO v4 Tiny.

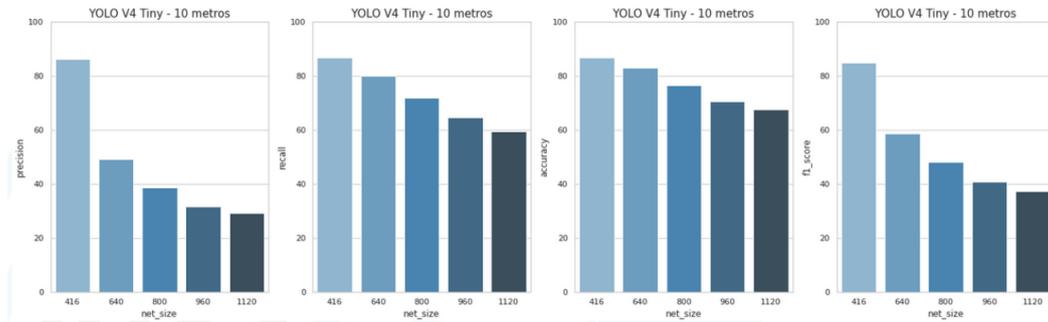


Fonte: Produção do autor.

Então, com objetivo de elevar os valores de *F1 Score* para esse conjunto de dados, foram feitos quatro redimensionamentos de 640, 800, 960 e 1120 na rede Tiny. Na Figura 2.17 quarto gráfico é possível observar que é formada uma queda de valores conforme aumento do tamanho da rede, enquanto que na Figura 2.18 quarto gráfico, o resultado é oposto, os valores de *F1 Score* aumentam. Essa melhoria pode ser justificada devido ao fato de que a rede redimensiona, também, as imagens e por consequência os objetos são aumentados proporcionalmente ao tamanho da nova imagem, melhorando assim o desempenho da detecção no conjunto de dados de 25

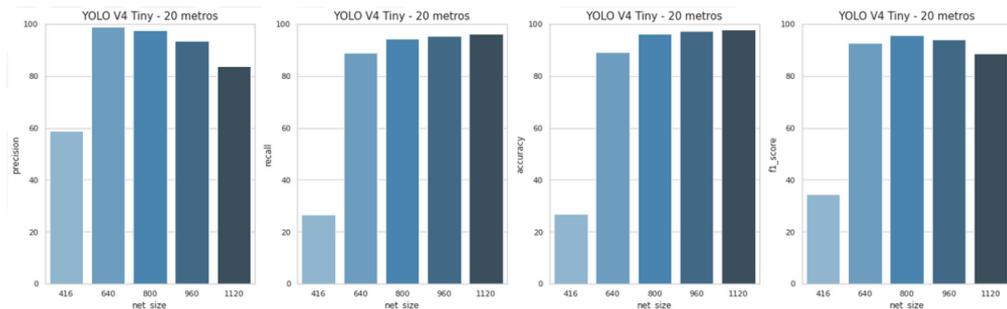
metros de altura.

Figura 2.17 - Gráfico das Métricas Extraídas da Matriz Confusão para Rede YOLO v4 Tiny Redimensionada.



Fonte: Produção do autor.

Figura 2.18 - Gráfico das Métricas Extraídas da Matriz Confusão para Rede YOLO v4 Tiny.



Fonte: Produção do autor.

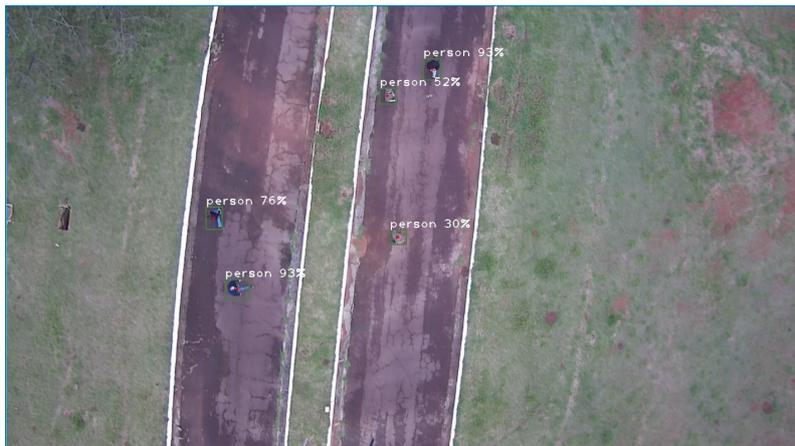
Comparando as Figuras 2.19 e 2.20 é possível verificar na prática a melhoria no desempenho da rede redimensionada para 640 na detecção de uma mesma imagem, na qual a imagem em que foi aplicado a rede com ajuste houve detecção de todos os objetos passíveis.

Figura 2.19 - Desempenho Rede YOLO v4 Tiny em imagem captada a 25 metros de altura



Fonte: Produção do autor.

Figura 2.20 - Desempenho Rede YOLO v4 Tiny redimensionada para 640 em imagem captada a 25 metros de altura

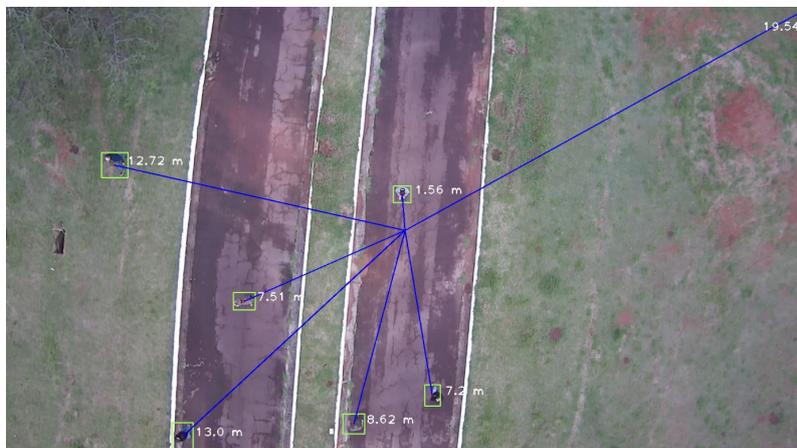


Fonte: Produção do autor.

Considerando a estimação de distância do objeto detectado em relação ao drone, foi utilizado a técnica GSD. A Figura 2.21 ilustra o resultado para o conjunto de dados de 25 metros. O centro de imagem simula a posição do drone, visto que se trata de uma visada NADIR. Sendo assim, pode-se concluir que nessas configurações de voo a rede detecta objetos presentes na imagens a 12.72 metros de distância do drone, o que não seria o suficiente para cumprir a norma. Para simular qual seria a maior distância possível de detecção de um objeto para voo de 25 metros de altura, foi simulado um ponto no superior direito da imagem, o que retorna 19.54

metros. Porém, essa distância ainda não seria o suficiente para cumprir norma.

Figura 2.21 - Estimativa de distância dos objetos detectados em imagem captada a 25 metros de altura



Fonte: Produção do autor.

3 CONCLUSÕES

Neste relatório, foram apresentadas as atividades desenvolvidas no período de 01 de setembro de 2021 a 31 de Agosto de 2022, referente ao projeto de pesquisa de iniciação científica "Detecção Automática de Pessoas Com Uso de Redes Neurais Convolucionais para Aplicações de Cálculo de Trajetória de Drones". Após análise dos resultados foi possível concluir que para alturas de voo de 10 e 25 metros a rede YOLO v4 e YOLO v4 tiny apresentam bom desempenho na detecção, o redimensionamento da rede YOLO v4 tiny, representa uma melhoria no desempenho da detecção para voos de 25 metros de altura e a visada NADIR não detecta objetos a 30m de distância do drone nas alturas de voo utilizadas para teste. Porém os dados coletados durante a pesquisa serão fundamentais para a realização de trabalhos futuros na área.

Finalmente, como linhas de pesquisa para trabalhos futuros sugere-se a comparação de desempenho entre as redes YOLO v4 e YOLO v7, estudos de aplicações das técnicas em imagens captadas por diferentes visadas, Estudo de aplicações de algoritmos de rastreamento de objetos em imagens para dar suporte ao avaliar o desempenho das RNC quando aplicado em uma sequência de imagens, estudo de técnicas de detecção de pequenos objetos e comparar com a solução de redimensionamento da rede e estudo de técnicas de estimativa de posição geográfica.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANAC. **Requisitos gerais para aeronaves não tripuladas de uso civil**. 2017. Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo_norma/RBACE94EMD00.pdf>. Acesso em: 12 de Abril 2021. 1
- AVANZATO, R. "a smart uav-femtocell data sensing system for post-earthquake localization of people". **IEEE Access**, 2020. 1
- AVANZATO R.; BERITELLI, F. "a smart uav-femtocell data sensing system for post-earthquake localization of people". **IEEE Access**, 2020. 1
- DECEA. **DECEA esclarece normas de voos de drones no Brasil**. 2018. Disponível em: <<http://www2.fab.mil.br/cenipa/index.php/ultimas-noticias/871-decea-esclarecenormas-para-voos-de-drones-no-brasil>>. Acesso em: 12 de Abril 2021. 1
- EICHHORN C.; JADID, A. P. D. A. W. S. K. G. I. Y. Catching the drone - a tangible augmented reality game in superhuman sports. **IEEE International Symposium on Mixed and Augmented Reality Adjunct (ISMAR-Adjunct)**, 2020. 1
- FENG K.; LI, W. G. S. P. F. "packages delivery based on marker detection for uavs,". **Chinese Control And Decision Conference (CCDC)**, 2020. 1
- LI, Y.; WANG, H.; DANG, L. M.; NGUYEN, T. N.; HAN, D.; LEE, A.; JANG, I.; MOON, H. A deep learning-based hybrid framework for object detection and recognition in autonomous driving. **IEEE Access**, p. 194228–194239, 2020. 1
- MITKA1 E.; MOUROUTSOS, S. "classification of drones". **American Journal of Engineering Research (AJER)**, 2017. 1
- NEVES, M. Drone fecha aeroporto de Congonhas pela 2o vez em um mês. portal r7, São Paulo. 2019. Disponível em: <<https://noticias.r7.com/sao-paulo/drone-fecha-aeroporto-de-congonhas-pela-2-vez-em-um-mes-09012019>>. Acesso em: 12 de Abril 2021. 1
- PARK J.; CHOI, S. A. I. K. J. "multiple uavs-based surveillance and reconnaissance system utilizing IoT platform,". **2019 International Conference on Electronics, Information, and Communication (ICEIC)**, 2019. 1
- REDMON J.; DIVVALA, S. G. R. F. A. "you only look once: Unified, real-time object detection,". **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, 2016. 2
- STÖCKER C.; BENNETT, R. N. F. G. M. Z. J. "review of the current state of uav regulations. remote sensing". **IEEE Access**, 2017. 1