

**UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

Inspeção de linha de transmissão utilizando  
multi-drones de baixo custo.

**Leandro Diniz de Jesus**

Itajubá, 12 de agosto de 2022

**UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM**  
**CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO**

**Leandro Diniz de Jesus**

**Inspeção de linha de transmissão utilizando  
multi-drones de baixo custo.**

Dissertação submetida ao Programa de Pós-Graduação em  
Ciência e tecnologia da computação como parte dos requisitos  
para obtenção do Título de Mestre em Ciências em Ciência e  
tecnologia da computação.

**Área de Concentração: Sistemas de Computação**

**Orientador: Prof. Dr. Alexandre Carlos Brandão  
Ramos**

**12 de agosto de 2022**

**Itajubá**

UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
CIÊNCIA E TECNOLOGIA DA COMPUTAÇÃO

Inspeção de linha de transmissão utilizando  
multi-drones de baixo custo.

Leandro Diniz de Jesus

Dissertação aprovada por banca examinadora  
em 15 de Junho de 2022, conferindo ao autor o  
título de **Mestre em Ciências e tecnologia da  
computação.**

***Banca Examinadora:***

Prof. Dr. Lina Maria Garces Rodriguez

Prof. Dr. Hildebrando Ferreira de Castro Filho

Itajubá

2022

Leandro Diniz de Jesus

## **Inspeção de linha de transmissão utilizando multi-drones de baixo custo**

Dissertação submetida ao Programa de Pós-Graduação em Ciência e tecnologia da computação como parte dos requisitos para obtenção do Título de Mestre em Ciências em Ciência e tecnologia da computação.

Trabalho aprovado. Itajubá, 15 de Junho de 2022:

---

**Prof. Dr. Alexandre Carlos Brandão  
Ramos**  
Orientador

---

**Prof. Dr. Lina Maria Garces  
Rodriguez**

---

**Prof. Dr. Hildebrando Ferreira de  
Castro Filho**

Itajubá  
12 de agosto de 2022

# Agradecimentos

Agradeço a Deus por me dar saúde e paciência para seguir toda essa trajetória acadêmica.

Gostaria de agradecer aos meus pais, Luiz Carlos e Fátima, que nunca deixaram que eu desistisse de correr atrás dos meus sonhos, mesmo nos momentos mais difíceis. Agradecer à minha irmã Diana e meu cunhado Wesley por sempre dar apoio e me motivar com a empolgação deles.

Queria agradecer não menos importante, à minha esposa Ana Paula, por sempre estar junto comigo, tendo paciência e compreensão no tempo que gastei dedicando aos estudos.

Agradecer ao meu orientador e grande amigo Alexandre Ramos, por todo o ensinamento, pelas conversas, por me apoiar quando precisei e sempre estar disposto a ajudar.

Último agradecimento vai para todos meus colegas que fiz ao longo do mestrado, aos meus amigos de Itajubá, meus parentes e meus amigos de Botucatu que nesses anos fizeram a diferença para conseguir chegar onde cheguei.

*"Primeiro, lembrem-se de olhar para as estrelas lá no alto e não para seus pés lá embaixo. Dois, nunca desistam do seu trabalho. O trabalho lhe dá sentido e propósito, e a vida é vazia sem isso. Três, se você for afortunado a ponto de encontrar amor, lembre-se de que ele está ali e nunca o jogue fora."*

*(Stephen Hawking)*

# Resumo

Periodicamente as linhas de alta tensão precisam ser inspecionadas para evitar problemas futuros, ou até mesmo, para resolver problemas que vão sendo notados. Para realizar essas inspeções as empresas vêm tentando fazer do modo mais seguro possível para que não haja um gasto muito alto e nem colocar nenhuma pessoa em risco. Para isso, profissionais dessas empresas vêm cada vez mais utilizando drones para inspecionar essas estruturas, porém esses drones necessitam de duas pessoas próximas, uma é o piloto controlando manualmente o drone e outra, um observador (também piloto) munido de binóculos e rádio para comunicação. As imagens geradas pelo drone são analisadas por um técnico que avaliará se e necessário tomar alguma medida para manter a Linha em funcionamento.

Para descobrir possíveis problemas na linha e estrutura essa pesquisa vem apresentar uma solução utilizando três drones realizando voo em conjunto de forma autônoma, que fará o processamento da imagem em tempo real de detecção dos possíveis problemas. O primeiro drone inicialmente irá se deslocar até a primeira torre com uma câmera, para que então utilizando uma rede neural convolucional, consiga detectar a torre e qualquer possível problema que se encontrar nela, além de gravar a localização da torre para que o especialista posteriormente efetue a manutenção, o segundo drone ficará responsável por verificar os fios que conduzem a energia elétrica e o terceiro drone ficará responsável por detectar invasões na área da linha que venha apresentar riscos ou vir a causar futuros problemas.

A implementação da solução foi realizada no simulador Airsim, onde foi desenvolvido um ambiente de código aberto disponibilizado para testes de navegação autônoma com uma linha de alta tensão. A navegação dos drones foi realizada a partir do posicionamento das torres onde já se sabe a localização da latitude e longitude de cada uma delas.

**Palavras-chaves:** Inspeção de linha de transmissão, Rede Neural Convolucional, Drones.

# Abstract

Periodically the electric power transmission lines need to be inspected to avoid future problems or even to solve problems that have been noticed. In order to carry out these inspections, companies have been trying to make it as safe as possible so that there is not a very high expense and do not put any person at risk, for this they are increasingly using drones to inspect, however these drones need to have people nearby operating navigation and with that it often ends up not being as efficient as it ends up passing some problem.

To solve the problem of detecting a possible problem on the line I come to present a solution using three drones that will make an autonomous flight over the line. The first drone will initially travel to the first tower and with a camera, using a convolutional neural network it will detect the tower and any possible problem that is found in it and record the location of the problem tower for someone to do maintenance on it, the the second drone will be responsible for checking the wires that conduct the electrical energy and the third drone will be responsible for detecting if there is something under the line that may be at risk or have come to cause future problems for the line.

The solution was implemented in the airsims simulator, where an environment already available by the software for autonomous navigation tests with a high voltage line was used. The navigation of the drones was made from the positioning of the towers where the location of the latitude and longitude of each one is already known.

**Key-words:** Transmission Line Inspection, Convolutional Neural Network, Drones.

# Lista de ilustrações

Figura 1 – Imagem do simulador Gazebo. Fonte: [SÁNCHEZ et al., 2016] . . . . .	20
Figura 2 – Imagem do simulador Airsim. Fonte: [SHAH et al., 2018] . . . . .	21
Figura 3 – Imagem da placa controladora Naza-M Lite com alguns componentes que vêm com ela. Fonte: [DJI, ] . . . . .	24
Figura 4 – Imagem da placa controladora APM ( <i>Arduino Pilot Meta</i> ) 2.6. Fonte: [TEAM, 2021a] . . . . .	25
Figura 5 – Imagem da placa controladora Pixhawk 2.4.6[TEAM, 2021c] . . . . .	25
Figura 6 – Imagem do frame F450. Fonte: Próprio autor . . . . .	26
Figura 7 – Diferenças de motor escovado e sem escova. Fonte: [SILVEIRA, 2016]. . . . .	27
Figura 8 – Motor utilizado no drone com o esc de 30 Ampere. Fonte: [ALI, 2020]. . . . .	27
Figura 9 – Módulo GPS. Fonte: Próprio Autor . . . . .	28
Figura 10 – Radio controle utilizado na pesquisa. Fonte: Próprio Autor . . . . .	28
Figura 11 – Interface do QGroundControl. Fonte: [INC, 2019]. . . . .	29
Figura 12 – Interface do Mission Planner. Fonte: [TEAM, ]. . . . .	30
Figura 13 – Ilustração da arquitetura de uma CNN. Fonte: [VARGAS; PAES; VASCONCELOS, 2016] . . . . .	31
Figura 14 – Imagem representando como o modelo YOLO ( <i>You only look once</i> ) funciona. Fonte: [REDMON et al., 2016] . . . . .	31
Figura 15 – Representação de acurácia com desempenho da YOLOv4 com as outras versões. Fonte: [BOCHKOVSKIY; WANG; LIAO, 2020] . . . . .	32
Figura 16 – Gráfico comparativo com os principais algoritmos do YOLO. Fonte: [NELSON, 2020] . . . . .	33
Figura 17 – Demonstração de desempenho da YOLOv5 em suas versões muito grande, grande, média e pequena. Fonte: [JOCHER, 2021] . . . . .	34
Figura 18 – Fluxograma dos experimentos realizados. Fonte: Próprio autor. . . . .	35
Figura 19 – Imagens do modelo de UAV montado de baixo custo, ainda sem gimbal e câmera. Fonte: Próprio Autor . . . . .	37
Figura 20 – Imagens obtida pelo voo teste realizado em um F450 em um mesmo local. Fonte: Próprio Autor . . . . .	38
Figura 21 – Imagens do simulador com mapa utilizado. Fonte: Próprio Autor . . . . .	39
Figura 22 – Apresentação da solução proposta. Fonte:[FILHO et al., 2021] . . . . .	40
Figura 23 – Comparação de treinamento com 100 épocas de um dataset com linha azul com 218 imagens e laranja é um dataset de 2243 imagens. . . . .	42
Figura 24 – Gráficos apresentando resultado do treinamento feito com a rede Yolov5. . . . .	43
Figura 25 – Imagens coletadas de um voo utilizando DJI Mavic e depois que executou a rede Yolov5. Fonte: Próprio Autor . . . . .	44

# Lista de tabelas

Tabela 2 – Quantidade de marcação das classes em cada dataset. . . . .	42
------------------------------------------------------------------------	----

# Lista de abreviaturas e siglas

API	<i>Application Program Interface</i>	20
APM	<i>Arduino Pilot Meta</i>	9
CNN	<i>Convolutional Neural Network</i>	30
ESC	<i>Eletronic Speed Control</i>	26
FPS	<i>Frames por second</i>	30
FPV	<i>First person view</i>	20
GNSS	<i>Global Navigation Satellite Systems</i>	27
GPS	<i>Global Positioning System</i>	24
IMU	<i>Inertial Measurement Unit</i>	23
IoT	Internet das coisas	32
Mavlink	<i>Micro Air Vehicle Link</i>	22
OSRF	<i>Open Source Robotics Foundation</i>	19
ROS	<i>Robot Operating System</i>	20
TCP	<i>Transmission Control Protocol</i>	21
UAV	<i>Unmanned Aerial Vehicle</i>	20
UDP	<i>User Datagram Protocol</i>	21
YOLO	<i>You only look once</i>	9
YOLOv5	<i>You only look once version 5</i>	13



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
1.1	Motivação	16
1.2	Escopo da pesquisa	16
1.3	Trabalhos relacionados	17
1.4	Objetivos	17
1.4.1	Objetivos Específicos	17
1.5	Estrutura do Trabalho	18
<b>2</b>	<b>MATERIAIS E MÉTODOS</b>	<b>19</b>
2.1	Simulação	19
2.1.1	Gazebo	19
2.1.2	Airsim	19
2.2	Framework	20
2.2.1	ROS	21
2.2.2	MAVSDK	22
2.3	Mavlink	22
2.4	Drones	22
2.4.1	Controladoras de voo	23
2.4.1.1	Naza-M Lite	24
2.4.1.2	Apm 2.6	24
2.4.1.3	Pixhawk 2.4.6	25
2.4.2	Frame	26
2.4.3	Motores	26
2.4.4	GPS	27
2.4.5	Rádio controle	28
2.5	GroundStation	29
2.5.1	QGroundControl	29
2.5.2	Mission Planner	29
2.6	Rede Neural Convolucional	30
2.7	YOLOv5 ( <i>You only look once version 5</i> )	31
<b>3</b>	<b>EXPERIMENTOS</b>	<b>35</b>
3.1	Montagem e testes de voos	35
3.2	Voo em simulador e teste da inteligência artificial com imagens reais	38
3.2.0.1	Modelagem de navegação	40
3.2.1	Treinamento da inteligência artificial	41

<b>4</b>	<b>CONCLUSÃO</b> . . . . .	<b>46</b>
<b>4.1</b>	<b>Discussões</b> . . . . .	<b>47</b>
4.1.1	Analisar algoritmos atuais de identificação de objetos que tenham capacidade para operar embarcados em drones . . . . .	48
4.1.2	Montar drones que possam fazer voos autônomos de forma segura e funcional	48
4.1.3	Utilizar um simulador que possa ser o mais parecido com o real para realizar testes de códigos desenvolvidos de modo que fique fácil a portabilidade para voos com drones reais . . . . .	49
4.1.4	Desenvolver um algoritmo de controle para que possa ser embarcado nos diferentes drones . . . . .	49
4.1.5	Conseguir realizar um comparativo das capacidades do simulador com o drone real . . . . .	50
<b>4.2</b>	<b>Trabalhos Futuros</b> . . . . .	<b>50</b>
<b>4.3</b>	<b>Considerações Finais</b> . . . . .	<b>51</b>
	 <b>REFERÊNCIAS</b> . . . . .	 <b>52</b>

# 1 Introdução

O Brasil possui mais de 141 milhões de km de linha de transmissão de energia elétrica e com uma projeção de um grande aumento ainda mais com o passar dos anos[RIBEIRO, 2019]. As empresas de distribuição de energia elétrica necessitam que sejam feitas inspeções periódicas nas linhas, para que dessa forma, haja manutenção evitando grandes falhas, e, manutenções preventivas impedindo aumento de custos e falta de energia elétrica em centros urbanos.

Em muitos países, as inspeções são realizadas a partir de um helicóptero onde possui um observador a bordo filmando e observando todo o trajeto para ver se encontra algo para se realizar a manutenção, porém desse modo o custo operacional é muito elevado e perigoso por colocar em risco quem esteja realizando essa operação pelo fato de que se tem a necessidade de chegar perto da linha para que seja observado algum possível problema que pode ser prevenido, porém existe um limite do distanciamento de prevenção para que não seja criado um arco elétrico podendo causar danos a pessoas, equipamentos ou ao helicóptero, como ocorrido no Brasil no dia 05 de junho onde um helicóptero possivelmente colidiu com a linha de transmissão elétrica, causando a morte dos ocupantes[GIANOTTO, 2022]. Para que consiga eliminar o risco humano que há nesse tipo de operação, também para baixar o custo, as empresas que realizam inspeção vêm fazendo isso com ajuda de drones, com ele foi possível eliminar helicópteros voando próximos da linha, porém ainda existe a necessidade que pessoas estejam próximas para operar esses drones, a partir do solo já que na regulamentação brasileira voo sem a interferência de um piloto é proibido.

Esses drones podem ser tanto de asa fixa como de asa rotativa, onde cada um apresenta seus benefícios por exemplo, se utilizarmos aeronaves de asa fixa podemos fazer uma cobertura diária bem maior, porém não teria como fazer uma inspeção tão detalhada pois um drone de asa fixa necessita ter uma certa velocidade para se sustentar em voo, enquanto o benefício de asa rotativa é o fato de conseguir fazer de forma um pouco mais lenta, porém com mais detalhes.

Entre as asas rotativas, temos helicópteros e os multirotores. A diferença imediata deles é a estabilidade que cada um apresenta durante o voo. Como em uma inspeção necessitamos que a câmera tenha a menor vibração possível, mesmo com gimbal que já estabiliza a imagem, vemos uma grande vantagem em multirotores pelo fato que eles, tem menos partes móveis o que permite uma filmagem mais estável e com menos vibrações.

Com o intuito de apresentar uma solução para as inspeções, o autor vem apresentar uma possível navegação com múltiplos drones, para que cada um mantenha o foco para uma parte da inspeção e uma técnica de Inteligência Artificial para detectar cada parte

de uma linha de transmissão e conseguir identificar e registrar possíveis problemas ou futuros problemas que possam ocorrer nessa linha.

Durante as etapas de desenvolvimento desse trabalho, foram gerados alguns artigos como "*Greater autonomy for RPAs using solar panels and taking advantage of rising winds through the algorithm*"[JESUS et al., 2019], "*A General Low Cost UAV Solution for Power Line Tracking*"[FILHO et al., 2020], "*Tracking for inspection in energy transmission power lines using unmanned aerial vehicles: a systematic review of current and specific literature*"[MARTINS et al., 2020], "*Increased autonomy for UAV using solar panels and take advantage of updrafts through algorithm*"[JESUS et al., ], "*Conditional integrator sliding mode control of an unmanned quadrotor helicopter*"[DIAZ-MENDEZ et al., 2022], "*Low-Cost UAV for Medical Delivery*"[DANTAS et al., b], "*Intelligent System for Detection and Identification of Ground Anomalies for Rescue*"[DANTAS et al., a], "*The use of 5G networks to control UAVs*"[GOMES et al., 2022] e "*Using UAV, IoMT and AI for Monitoring and Supplying of COVID-19 Patients*"[DANTAS et al., 2021].

## 1.1 Motivação

No cenário atual vemos que as empresas estão utilizando drone para inspeção, porém é necessário ter um piloto no controle realizando a filmagem de forma manual. Normalmente o piloto do drone não é especialista em linhas de transmissão, então, a filmagem é analisada por outra pessoa procurando algum problema na linha como cabos quase se rompendo ou mesmo um possível futuro problema que pode aparecer na torre pelo fato de ferrugem e até mesmo analisar se tem algo no solo que está invadindo a área das torres, por exemplo, árvores ou habitações clandestinas que, por lei, não poderiam estar no local.

Então pensando nesse cenário, com a ajuda de inteligência artificial é possível fazer uma análise em tempo real para que possa identificar e já registrar os locais com possíveis problemas. Porém com o gargalo de hardware que teria em se fazer todas análises com apenas um drone. Foi considerado a utilização de mais drones para que cada um faça análise de cada cenário.

## 1.2 Escopo da pesquisa

Com o intuito de diminuir custos, aumentar a eficiência e simplificar a inspeção de linhas de transmissão, este trabalho de pesquisa propõe a utilização de múltiplos drones, cada um realizando uma determinada missão relacionada a inspeção de forma automatizada, com o apoio de algoritmos de Inteligência Artificial para identificar defeitos comparando os principais elementos (cabos, junções de cabos, ligações com isoladores

etc.) com padrões preestabelecidos desses elementos.

## 1.3 Trabalhos relacionados

Iniciando uma busca na literatura acadêmica vemos muitos trabalhos bons sendo executados com utilização de drones para detecção de objetos onde oferece muita evolução tanto na parte dos laboratórios de pesquisa como para o mercado de trabalho, apresentando várias soluções. Porém para se localizar trabalhos no estado da arte foi necessário elaborar uma *string*, onde foram utilizadas palavras-chaves para compor a *string*, onde gera um filtro mostrando os melhores trabalhos relacionados no assunto.

Existem alguns trabalhos que demonstram que a utilização da YOLOv5 no estado da arte, está apresentando um melhor desempenho como os trabalhos do [WU; WANG; LIU, 2021], [PHADTARE et al., 2021] e [ZHOU et al., 2021]. Esses são alguns de exemplos de trabalhos que demonstram que para detecção de objetos na utilização de drones está no estado da arte.

## 1.4 Objetivos

O principal objetivo do presente trabalho é desenvolver estratégias para realizar a inspeção de linhas de transmissão de energia elétrica reduzindo custos e identificando falhas de forma rápida e eficiente a partir da utilização de drones, trabalhando paralelamente e com o apoio de sensores, piloto automático e computadores de bordo que implementam algoritmos de Inteligência Artificial para identificação de defeitos em elementos de inspeção (junções de cabos, ligações de cabos com isoladores etc.).

Resultados preliminares foram obtidos a partir da implementação, em simulador, das estratégias desenvolvidas.

### 1.4.1 Objetivos Específicos

Os objetivos específicos são:

- (a) Analisar algoritmos atuais de identificação de objetos que tenham capacidade para operar embarcados em drones.
- (b) Montar drones que possam fazer voos autônomos de forma segura e funcional.
- (c) Utilizar um simulador que possa ser o mais parecido com o real para realizar testes de códigos desenvolvidos de modo que fique fácil a portabilidade para voos com drones reais.

- (d) Desenvolver um algoritmo de controle para que possa ser embarcado nos diferentes drones.
- (e) Conseguir realizar um comparativo das capacidades do simulador com o drone real.

## 1.5 Estrutura do Trabalho

Essa dissertação foi estruturada do seguinte modo:

- No Capítulo 2 serão apresentados os estudos realizados sobre os componentes utilizados e métodos teóricos compostos nesse trabalho.
- No Capítulo 3 será apresentado como foram realizados os testes do algoritmo desenvolvido e como foram montados os drones utilizados na pesquisa.
- No Capítulo 4 são apresentadas a conclusão, as contribuições desse trabalho e sugestões para trabalhos futuros.

## 2 Materiais e Métodos

Nesse capítulo são apresentados os métodos, técnicas e ferramentas utilizadas no desenvolvimento da pesquisa. Para a realização do trabalho foi necessário estudar simuladores de voo, componentes eletrônicos, ferramentas de monitoração e controle de voo além do desenvolvimento de algoritmos de Inteligência Artificial para reconhecimento de objetos tanto nas linhas de transmissão quanto no solo.

### 2.1 Simulação

Nem sempre é viável que seja testado um algoritmo direto em um equipamento que pode ter um custo muito alto ou até mesmo levar um tempo muito grande para que seja montado outro parecido, trazendo um grande atraso na pesquisa. Para que isso não ocorra utilizamos simuladores onde é possível simular o equipamento que vai ser utilizado e o ambiente onde ele será usado para testar algoritmos de forma segura e rápida.

Em questão de drones, existem alguns simuladores comuns que são de código aberto, onde alguns deles é possível customizar mapas e simular as condições de ambientes reais a que temos.

Temos dois principais simuladores utilizados que são o Gazebo e Airsim.

#### 2.1.1 Gazebo

Um dos simuladores de robótica 3D mais utilizado é o Gazebo, que foi desenvolvido principalmente para testes de algoritmos junto a sensores. Nele é possível criar mapas, recriar robôs com atuais sensores e realizar testes de algoritmos.

Começou a ser desenvolvido em 2002 na Universidade da Califórnia do sul, onde a maior necessidade era desenvolver um simulador com maior fidelidade com o real para fazer simulações de robôs em ambientes fechados e de 2012 para frente a [OSRF \(Open Source Robotics Foundation\)](#), junto a comunidade de desenvolvedores na área de robótica assumiu o desenvolvimento do simulador[[FOUNDATION, 2014](#)]. Uma imagem da interface é apresentada na Figura 1.

#### 2.1.2 Airsim

Airsim é um simulador desenvolvido pela Microsoft, ele foi desenvolvido na ferramenta da *Unreal Engine*, que é a mesma ferramenta que desenvolve jogos. O grande objetivo dela é realizar testes de inteligência artificial em veículos autônomos, através de




Figura 1 – Imagem do simulador Gazebo. Fonte: [SÁNCHEZ et al., 2016]

API (*Application Program Interface*) que fornece e possui biblioteca própria para controle independente dos veículos [RESEARCH, 2021].

A principal diferença dele é o fato de que já existe uma API criada onde oferece imagens de câmeras, onde as imagens que se obtém é de profundidade, de segmentação e uma visão FPV (*First person view*). A Figura 2 apresenta a tela do simulador.

## 2.2 Framework

Framework é um ambiente de software onde o principal objetivo é facilitar o desenvolvimento através de várias bibliotecas integradas que são constantemente utilizadas, fazendo com que o desenvolvedor tenha maior dedicação para solucionar o problema em si.

Existem muitos tipos de frameworks como para desenvolvimento web, para desenvolvimento de Inteligência Artificial, como também temos frameworks usados para parte de robótica ou até mesmo para drones. Alguns bastante utilizados para desenvolvimento de robótica em geral é o sistema do ROS (*Robot Operating System*) e um dos frameworks voltados especificamente para placas controladoras de UAV (*Unmanned Aerial Vehicle*) é o MAVSDK.



Figura 2 – Imagem do simulador Airsim. Fonte: [SHAH et al., 2018]

### 2.2.1 ROS

**ROS**, na tradução literal é sistema operacional para robótica, onde possui um conjunto de bibliotecas e ferramentas que estão no estado da arte para ajudar no desenvolvimento de aplicações voltadas para robótica e é de código aberto.

É uma ferramenta muito poderosa, onde possibilita desenvolver tanto sistemas robóticos simples, quanto sistemas mais complexos. O sistema é totalmente distribuído através de nós de publicação/subscrição, que por exemplo, um sensor publica o que ele está lendo e em outro tópico é possível fazer publicação para que o robô execute um determinado comando.

Possui uma comunidade ativa, onde é possível ter ajuda, caso tenha algum problema. Atualmente possui duas versões que se diferenciam no modo em que é feita a comunicação, na versão 1 a comunicação é feita através de **TCP** (*Transmission Control Protocol*) e na versão 2 é feita através do **UDP** (*User Datagram Protocol*). A ideia é na versão 1 ter um meio de comunicação onde se tem mais segurança, onde as informações são enviadas e possui um retorno falando se deu certo ou não, esse tipo de comunicação é um pouco demorado e na versão 2 o foco é ter uma comunicação mais rápida, porém sem verificação se houve algum erro no envio.

Existem alguns trabalhos que demonstram o potencial desse framework utilizando múltiplos drones como os apresentados em [BARCIŚ; BARCIŚ; BETTSTETTER, 2019]

e [KHALIQ; AHSAN; NISAR, 2021].

### 2.2.2 MAVSDK

MAVSDK é focado para sistemas que fazem interface com o MAVLink como drones, câmeras e estação de solo. Ele é um conjunto de bibliotecas que funcionam em diferentes linguagens que podem controlar um ou mais de um veículo, tendo acesso aos seus sensores através da telemetria, podendo também enviar comandos através dela. [FOUNDATION, 2021]

O sistema pode funcionar em qualquer dispositivo, podendo ser embarcado, em uma estação de solo ou até mesmo em um dispositivo móvel.

Para realizar a comunicação com diferentes veículos, para cada um é fornecido um endereço IP individual.

## 2.3 Mavlink

Mavlink (*Micro Air Vehicle Link*) é um protocolo de comunicação que apareceu pela primeira vez em 2009 por Lorenz Meier.

Possui uma mesclagem de técnicas de computação distribuída que consistem em publicação-subscrição e de ponto-a-ponto. [PROJECT, 2022]

A técnica de publicação-subscrição funciona de modo que possui um tópico onde nele possui informações provenientes de sensores que podem ser lidos e também tópicos que podem ser publicados para que faça alguma ação. Pensando em sistema ponto-a-ponto são aqueles onde não existe a necessidade de uma interação ou que todos recebem informações de sensores, esse sistema é utilizado para fazer alterações de configurações como alteração de parâmetro ou para criar missões através de *waypoints*.

Esse protocolo é muito leve e muito utilizado para comunicação entre placas controladoras e a estação de solo.

As mensagens são trocadas utilizando arquivos XML.

## 2.4 Drones

Drones vem sendo muito utilizados para vários tipos de serviços atualmente, como mapeamento de um terreno, inspeção de uma região para avaliar desmatamento ou alguns outros tipos de serviços que são muito importantes e que utilizando outros tipos de aeronaves fica muito caro.

Porém temos classes diferentes de drones como os de asas rotativas e de asas fixas. Cada um deles tem seus benefícios como melhor aproveitamento da bateria, maior autonomia, ou a possibilidade de voar em velocidades muito baixas e até mesmo parar o ar e voar para trás.

Um trabalho muito relevante é o desenvolvido por Boon, onde foi realizada a comparação de um drone de asa fixa e um de multirotor para ver onde cada um se sobressai sobre o outro. No trabalho vemos que para multirotor a questão de estabilidade e capacidade de um maior carga útil é favorável, enquanto para asa fixa o que mais se destaca é o fato de que o tempo de voo é muito maior [BOON; DRIJFHOUT; TEFAMICHAEL, 2017]. No presente trabalho, o mais importante é manter estabilidade de voo para que se tenha uma imagem mais estável possível para que se consiga ver com maior precisão mudanças na área.

Foi estudada a possibilidade de se utilizar uma possível mistura de drones tendo asas fixas com placa solar onde se consegue um tempo maior de voo, porém para que seja feita uma inspeção preventiva são necessárias imagens com mais detalhamento das linhas para que se consiga ver algo relevante e como um drone de asa fixa não possui a possibilidade de voar em baixas velocidades, seu uso foi descartado.

Uma vez escolhido o tipo de aeronave, foi realizado um estudo de mercado para avaliar os principais componentes de baixo custo que permitam customizar as configurações de piloto automático e que aceitem códigos desenvolvidos em um sistema embarcado ou até mesmo de uma *groundstation*<sup>1</sup>.

### 2.4.1 Controladoras de voo

Foram analisadas algumas controladoras de voo de baixo custo que permitem a função de voo autônomo. Elas foram a Naza M Lite da empresa DJI, APM 2.6 e Pixhawk 2.4.6.

Todas as controladoras estudadas possuem IMU (*Inertial Measurement Unit*) interno que trabalha detectando aceleração linear usando um ou mais acelerômetros e taxa de rotação usando um ou mais giroscópios. Alguns também incluem um magnetômetro que é usado como referência de direção. As configurações típicas contêm um acelerômetro, giroscópio e magnetômetro por eixo para cada um dos três eixos principais: inclinação, rotação e guinada.

---

<sup>1</sup> Também conhecido como estação de solo, que é um notebook que fica recebendo informações de voo e tem a possibilidade de enviar comandos

### 2.4.1.1 Naza-M Lite

Naza é uma controladora desenvolvida pela empresa privada conhecida como DJI, muito utilizada nos UAVs da empresa.

Apesar de ser uma placa controladora muito boa, ela tem um acesso muito restrito para suas configurações. Uma imagem dela é apresentada na Figura 3.



Figura 3 – Imagem da placa controladora Naza-M Lite com alguns componentes que vêm com ela. Fonte: [DJI, ]

### 2.4.1.2 Apm 2.6

Apm 2.6 foi lançado junto com a Apm 2.5 em 2012 pela *3D Robotics* junto com o time ArduPilot[TEAM, 2021b]. As duas placas apresentam o mesmo hardware diferenciando o fato de que na placa Apm 2.5 vem com um compasso interno e necessita de um módulo GPS (*Global Positioning System*) da Mediatek, onde se destaca em asa fixa que necessita de uma resposta mais rápida ao movimento. A placa Apm 2.6 não possui bússola interna e nela é necessário um módulo com bússola e GPS que é o Ublox. Ambos foram desenvolvidos na plataforma de um Arduino, onde possui uma ampla utilização em drones. As duas placas possuem um fácil acesso aos parâmetros de configuração, porém foram descontinuadas[TEAM, 2021a].

Processador utilizado tem a capacidade de processamento de 16 bits, dentro da placa vem integrado barômetro, acelerômetro e giroscópio. A imagem dela é apresentada

na Figura 4.



Figura 4 – Imagem da placa controladora APM 2.6. Fonte: [TEAM, 2021a]

#### 2.4.1.3 Pixhawk 2.4.6

Primeira PX4, foi desenvolvida em 2012 que possui um software de controle de voo e eletrônicos para piloto automático. Porém a versão possuía muitos problemas e apenas um ano depois foi lançado a primeira placa controladora com a parceria da *3D Robotics*[TEAM, 2021b]. A intenção dos desenvolvedores era fazer uma placa controladora de voo com capacidade de visão computacional que fosse acessível a todos, por isso o software é de código aberto.

Nela há um processador que tem a capacidade de interpretar até 32 bits de informação, um dos principais fatores de ser utilizada por muitos desenvolvedores. A imagem dela é apresentada na Figura 5.



Figura 5 – Imagem da placa controladora Pixhawk 2.4.6[TEAM, 2021c]

### 2.4.2 Frame

Frame de um UAV é a estrutura em que ele é montado. Essa estrutura pode ter vários formatos cuja configuração é definida na placa controladora para que possa realizar os ajustes dos controles dos motores.

Foi escolhido um F450 que é um frame para quadrirotor ou seja possui 4 motores e muito comum de ser encontrado no mercado. A vantagem desse frame é pelo fato dele ter um ótimo espaço para se colocar equipamentos em sua estrutura. A Figura 6 mostra o frame utilizado no estudo.



Figura 6 – Imagem do frame F450. Fonte: Próprio autor

### 2.4.3 Motores

Existem dois tipos de motores que funcionam com corrente contínua, são eles os motores com escova e sem escova, representados na Figura 7. Nos drones maiores temos uma utilização de motores sem escovas pelo fato de ter um menor desgaste de peças mecânicas, conseguir trabalhar em velocidades maiores pelo fato de que aquecem menos devido ao menor índice de atrito [MATHIE, 2017].

Junto ao motor temos o **ESC** (*Electronic Speed Control*), ou controlador eletrônico de velocidade, que interpretam os comandos enviados pela controladora e determina a corrente correta enviada para os motores. Cada **ESC** faz um controle de uma determinada corrente máxima que pode ser enviada para o motor. Ao adquirir um motor ele já vem com informações do **ESC** ideal para o funcionamento, sendo que se colocar um **ESC** diferente acaba gerando ruídos no comando enviado e instabilidade para o voo. Esses componentes são apresentados na Figura 8.

As hélices são determinadas pelo fabricante do motor para que haja uma maior estabilidade de voo. Fato importante é que utilizando uma hélice errada, pode gerar um



Figura 7 – Diferenças de motor escovado e sem escova. Fonte: [SILVEIRA, 2016].



Figura 8 – Motor utilizado no drone com o esc de 30 Ampere. Fonte: [ALI, 2020].

maior consumo de energia, tendo menos tempo de voo.

#### 2.4.4 GPS

GPS, ou sistema de posicionamento global, é um componente vital quando pensamos em voo autônomo, sua imagem é apresentada na Figura 9. Ele determina a localização relativa do UAV através de satélites em órbita.

Para obter a localização é realizado o cruzamento de informações obtidas de vários satélites. É comum se ter módulos de GPS que se conectam com nove satélites ou mais tendo uma maior precisão de localização por quanto mais satélite tem conectado a ele, chegando a ter precisão de centímetros para GPS mais sofisticados.[CIOBANU, 2022]

Esse tipo de equipamento é muito importante caso for realizar voos com pontos específicos em latitude e longitude. Sabendo onde se localiza o UAV, o sistema consegue determinar para onde tem que ir para chegar a um ponto específico.

O GPS é um tipo de sistema GNSS (*Global Navigation Satellite Systems*), ou



Figura 9 – Módulo GPS. Fonte: Próprio Autor

sistema global de navegação por satélite desenvolvido pelos Estados Unidos da América. Os sistemas GNSS mais conhecidos são: na Europa foi desenvolvido um sistema chamado Galileo, na Rússia Glonass e na China BeiDou.

#### 2.4.5 Rádio controle

Radio é o que determina o controle manual do drone, ele é composto por um controle com sticks para movimentação do drone em cada eixo, possui um receptor de sinal que vai na placa controladora que é onde recebe os comandos enviados pelo controle e repassa para controladora determinar o que cada motor vai ter que fazer.



Figura 10 – Radio controle utilizado na pesquisa. Fonte: Próprio Autor

## 2.5 GroundStation

Estação de solo trata-se de um computador, normalmente do tipo notebook e que é muito importante quando se fala de voo autônomo, pois nela o operador pode acompanhar o voo através da telemetria, tendo informações de localização, altitude, velocidade e muitas outras informações pertinentes ao voo.

Outra função importante da estação de solo é fazer a calibragem dos sensores utilizados.

Existem várias estações de solo, as principais que serão descritas com um pouco mais de detalhes nas próximas seções, são Mission planner e QGroundControl.

### 2.5.1 QGroundControl

QGroundControl é uma estação de solo desenvolvida para aceitar dispositivos que utilizam o protocolo MAVLink. Nele é possível ter um controle total do voo, podendo elaborar missões através de pontos do mapa.

É um software que roda em qualquer plataforma e suporta qualquer tipo de veículo que pode utilizar uma placa controladora. A tela do software é apresentada na Figura 11.

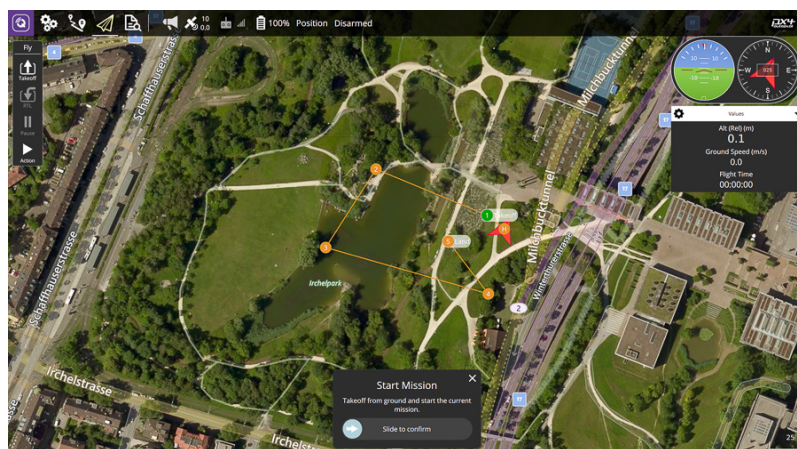


Figura 11 – Interface do QGroundControl. Fonte: [INC, 2019].

### 2.5.2 Mission Planner

Mission Planner é uma estação de solo compatível apenas com Windows, onde foi feita para aviões, veículos rotativos e carro, sua interface é apresentada na Figura 12. É uma estação de solo bem completa onde possui todas as informações de controle da placa controladora, nele também é possível criar missões para que seja realizada de forma autônoma.

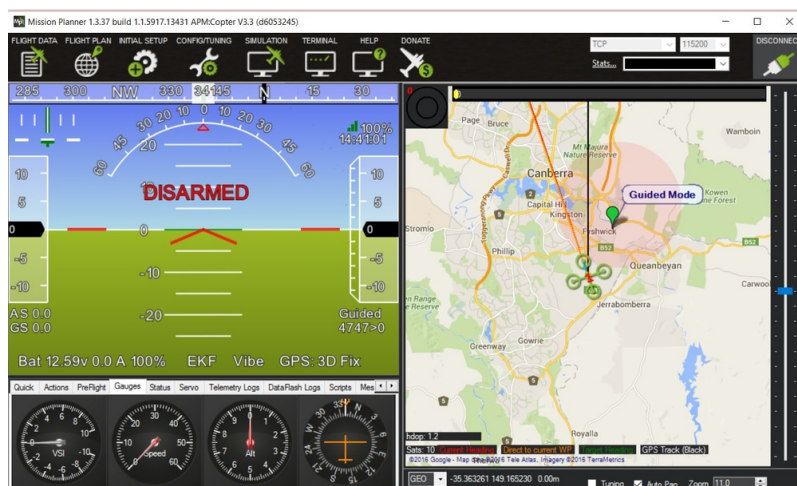


Figura 12 – Interface do Mission Planner. Fonte: [TEAM, ].

## 2.6 Rede Neural Convolutacional

Redes Neurais Convolucionais, também conhecida como *CNN (Convolutional Neural Network)*, nesse trabalho tem como principal funcionalidade a capacidade de aprender as características de uma imagem e com isso a possibilidade de identificar objetos pela imagem.

Basicamente a rede consiste em camadas de convolução e camadas de *pooling*. Nessas camadas se obtém as características das imagens como bordas, intensidade de cor, contornos e formas. Ao final ela é passada por uma camada completamente conectada onde se faz a classificação da imagem.[PENHA et al., 2018]

Para melhor explicar como funciona é apresentado na Figura 13 que temos uma imagem de entrada que é submetida a extração de características, nela temos a camada de convolução onde são aplicados filtros para extrair características e em seguida essa convolução passa por uma camada conhecida como pooling que produz um outro mapa de características de forma reduzida[SAMER; RISHI; CHRIS, 2015], para que depois passe por outras camadas de convolução e pooling, até chegar na camada completamente conectada que realiza a classificação das características da imagem.

Pelo fato da necessidade de que os algoritmos pudessem rodar em sistemas embarcados, foram realizadas alterações no modo como são extraídas as características da imagem. Com isso foram analisadas técnicas no estado da arte que estão sendo implementadas em sistemas embarcados e duas se destacaram que são a *Faster R-CNN* e a *YOLOv5*.

Para decidir qual das duas utilizar nesse trabalho foi analisado o requisito do *FPS (Frames por second)* e acurácia da rede. No [DWIVEDI, 2020] foram feitos testes de desempenho de detecção e conseguiram chegar a conclusão que o *YOLOv5* se sai melhor como um algoritmo mais rápido do que o *Faster R-CNN*.

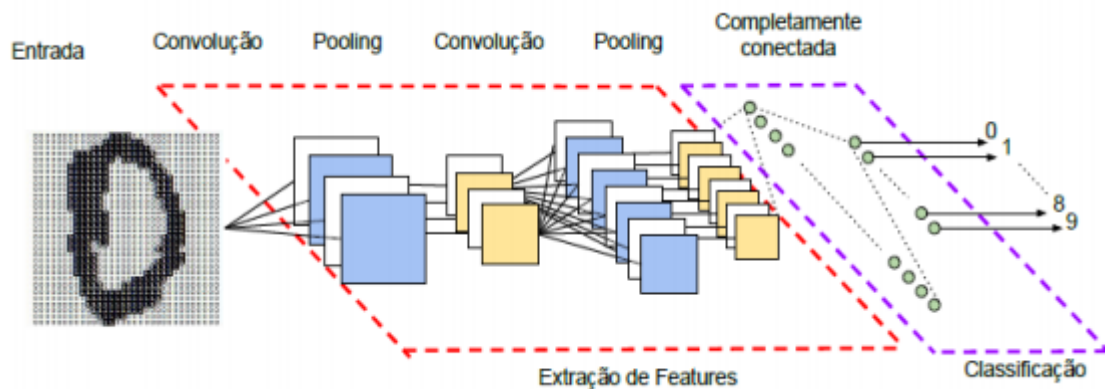


Figura 13 – Ilustração da arquitetura de uma CNN. Fonte: [VARGAS; PAES; VASCONCELOS, 2016]

## 2.7 YOLOv5

A primeira versão da **YOLO** foi apresentada no ano de 2016 por Joseph Redmon [REDMON et al., 2016], onde mostrou um grande diferencial em questão de performance, conseguindo atingir 45 FPS e possuía um tamanho muito pequeno que se tornou uma técnica ideal para a utilização em tempo real.

A proposta é tentar simplificar o modo de detecção dos modelos na imagem, como apresentado Figura 14, pode-se ver que a imagem é dividida em uma matriz, onde ela é passada por uma rede de convolução, que acaba realizando a marcação de caixa nas características da imagem e um mapa de probabilidade de classes presentes na imagem, em seguida é realizado a classificação da imagem com os objetos reconhecidos.

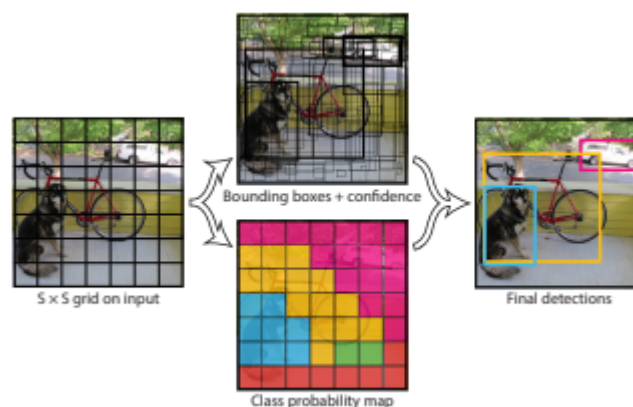


Figura 14 – Imagem representando como o modelo YOLO funciona. Fonte: [REDMON et al., 2016]

Porém esse modelo foi sendo aprimorado com o passar do tempo com mais duas versões feitas pelo próprio Joseph sendo apresentado nos artigos "YOLO9000: Better, Faster, Stronger." [REDMON; FARHADI, 2017] que foi publicado em 2017, conhecido como

segunda versão apesar do nome e terceira versão com o artigo “YOLOv3: An Incremental improvement.” que foi publicado em 2018 [REDMON; FARHADI, 2018].

Após a versão 3, outra equipe assumiu o aprimoramento, que foi composta por Alexey Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao e lançaram uma versão 4 com o artigo "YOLOv4: Optimal Speed and Accuracy of Object Detection", que foi lançado em 23 de abril de 2020 [BOCHKOVSKIY; WANG; LIAO, 2020]. Essa versão chegou como a mais rápida em detecção em tempo real como pode ser vista na Figura 15.




Figura 15 – Representação de acurácia com desempenho da YOLOv4 com as outras versões. Fonte: [BOCHKOVSKIY; WANG; LIAO, 2020]

Em 9 de junho de 2020, foi apresentado uma versão 5 por Glenn Jocher, fundador e CEO da empresa Ultralytics LLC. Essa versão veio sem ter nenhum vínculo com as versões anteriores da YOLO.

Pelo fato da YOLOv5 ter sido implementado em python, tornou a integração de dispositivos IoT (Internet das coisas) mais fáceis e com uma comunidade muito maior do que a Darknet que era usada nas versões anteriores. [THUAN, 2021]

Através da figura 16, podemos ver que o YOLOv5 tem uma velocidade de detecção muito parecido com as versões anteriores e que sua acurácia é um pouco superior às duas outras.

Por ter sido uma implementação muito recente, YOLOv5 vem sendo cada vez mais aprimorada onde nela contém versões de treinamento com uma acurácia bem mais alta, porém tendo um arquivo de pesos muito grande como também foi desenvolvido uma

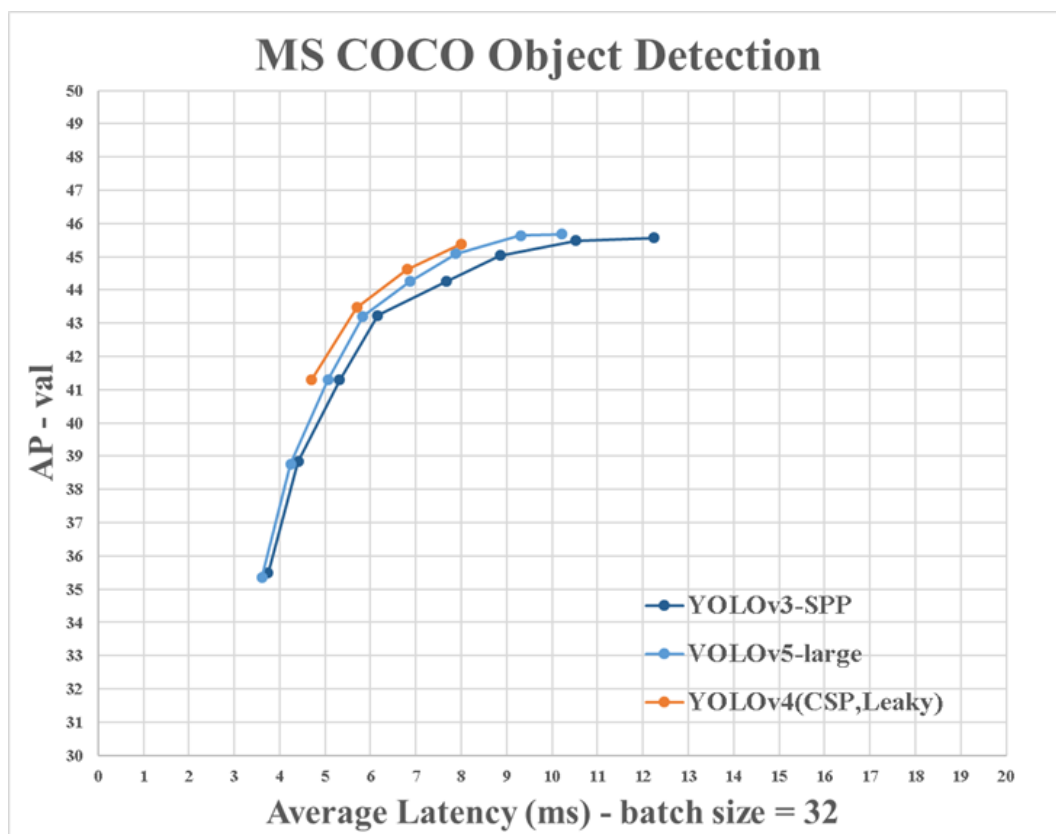


Figura 16 – Gráfico comparativo com os principais algoritmos do YOLO. Fonte: [NELSON, 2020]

versão menor do seu código com uma acurácia um pouco menor para que seja rodado em dispositivos embarcados preservando assim a memória e aumentando a velocidade das redes nesse tipo de sistema onde possui um hardware mais limitado. A Figura 17 mostra o comparativo.




Figura 17 – Demonstração de desempenho da YOLOv5 em suas versões muito grande, grande, média e pequena. Fonte: [JOCHER, 2021]

## 3 Experimentos

Nesse capítulo serão apresentados os experimentos realizados em laboratório com equipamento real e partes desenvolvidas em simulador. Na etapa inicial do experimento, foi realizado um estudo para definir o UAV mais apropriado para o propósito do trabalho e foi realizado a montagem do mesmo para ver o desempenho em voo do equipamento. Na segunda etapa foi realizado em simulador do código desenvolvido para realizar o voo e foi testada a rede neural em filmagens reais obtidas através de voos.

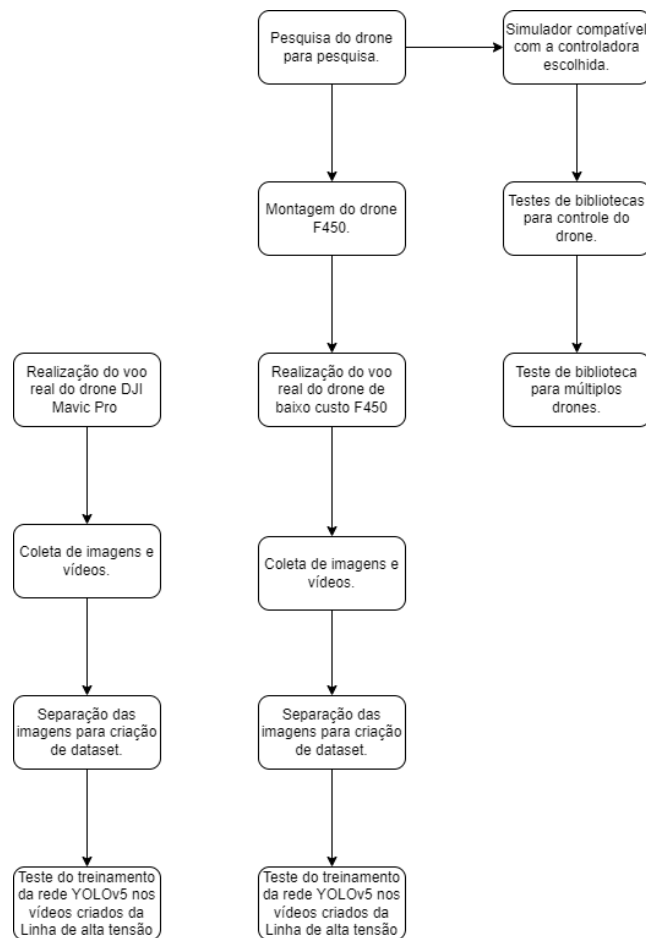


Figura 18 – Fluxograma dos experimentos realizados. Fonte: Próprio autor.

Na figura 18 é apresentado o fluxograma de como foi desenvolvido esse trabalho, sendo realizado algumas etapas em paralelo para que consiga seja feito um comparativo.

### 3.1 Montagem e testes de voos

Nessa primeira parte foi realizado um estudo sobre os diferentes tipos de UAV e suas principais utilizações para se definir qual o mais apropriado para realizar a inspeção.

Um dos grandes problemas do UAV é a duração da bateria, então inicialmente foi cogitada a possibilidade de se utilizar um de asa fixa para fazer uma inspeção mais rápida com a necessidade de enviar um quadricóptero para que seja feita uma fiscalização mais detalhada do local. Porém o fato é que teria que fazer dois serviços para que a inspeção consiga ser mais eficiente, pelo fato de um UAV de asa fixa não conseguir manter uma velocidade baixa para que a inteligência artificial tenha tempo de fazer uma identificação, então foi optado por utilizar apenas quadricópteros que possuem uma maior estabilidade que outros UAV rotativos e conseguem fazer uma navegação mais lenta.

Tendo em visto os quadricópteros, foram analisadas as principais placas controladoras utilizadas no mercado que possuem um baixo custo, foram a naza-m lite, apm 2.6 e pixhawk. Para que definisse a ideal para se utilizar, foram testadas as 3 em voos reais onde primeiro voo foi feito para se analisar a leitura dos sensores, segundo foi para analisar como se comportava em voos autônomos através de missão com waypoints e terceiro foi analisado através de códigos desenvolvidos com framework mavsdk.

Entre elas a que não teve um bom desempenho foi a apm 2.6 pelo fato de que o barômetro que vem interno da IMU da placa apresentou muita inconsistência na altitude de voo e pelo fato de que só aceita comandos de 16 bits, então ao testar códigos desenvolvidos com o mavsdk, havia muitos problemas de erro ao receber o comando e assim fazia a função de land sem executar aquilo que era proposto. Quanto ao voo com missão ele se saiu próximo ao desejado, fazendo o trajeto estipulado.

A placa naza pelo fato de ser desenvolvida por uma empresa privada, não há muitas configurações que podem ser feitas. Em voo de missão seus sensores corresponderam muito bem, realizando a missão com precisão e tendo o UAV bem estável no voo. Porém não foi possível fazer comunicação com o Mavsdk para testar o controle por código.

Com isso optamos por utilizar a placa da pixhawk por apresentar um bom desempenho em todos os três quesitos. Outro grande motivo para utilização dela foi o fato de que a comunidade ser muito ativa, conseguindo obter ajuda para solucionar algum possível problema muito facilmente.

Todos os outros componentes do UAV foram testados sem alteração que foram 4 motores a2212/13T de 1000KV, 4 ESC Readytosky 30 ampere, frame do UAV F450, uma base amortecedora para diminuir a vibração das placas controladoras, receptor de rádio FlySky FS-r9b, telemetria de 915 MHz, GPS com bússola Ublox m8n, power modulo g m v1.0. No caso de se utilizar uma Pixhawk foi colocado um ppm encoder para fazer a transmissão de sinal do receptor de rádio para placa controladora, foi utilizado um gimbal desenvolvido com servos eletrônicos, com uma câmera filmadora Sports 4k Ultra HD. O modelo completo é apresentado na Figura 19.

No processo de teste das placas controladoras, foi feito teste em algumas estações



Figura 19 – Imagens do modelo de UAV montado de baixo custo, ainda sem gimbal e câmera. Fonte: Próprio Autor

de solos onde entre os testados as que deram mais compatibilidade foi o Mission Planner e QgroundControl. Porém pela necessidade de que muitas bibliotecas que foram experimentadas para realizar testes de voo autônomo ser mais compatível com Linux, foi escolhido a estação de solo QGroundControl por ter essa compatibilidade.


O que ajuda obter um voo mais estável é o fato de se calibrar os sensores de modo correto, onde cada estação de solo tem seu modo de configuração e a QGroundControl possui imagens muito didáticas para que seja feito esse ajuste da melhor forma possível.

Foram realizados alguns voos com uma Raspberry Pi embarcado com a utilização do framework [ROS](#), onde foi criado um código para navegação autônoma com parte embarcada e outra parte rodando na estação de solo. Foram feitos testes também utilizando o MAVSDK que é um conjunto de bibliotecas que faz interface com o MAVLink (Utilizado principalmente em estações de solo), onde realiza conexão pela telemetria e assim roda códigos de navegação [[FOUNDATION, 2021](#)].

Entre os voos realizados com esse UAV foi feito um voo sobre a linha de alta tensão, porém pelo fato de que o gimbal utilizado não funcionar muito bem, ele não conseguiu diminuir a vibração da câmera, com isso a [Figura 20](#) com imagens obtidas durante esse voo não pode ser aproveitado para o teste da rede [YOLOv5](#).

Apesar do gimbal não ter sido muito bem aproveitado foi montado mais dois UAVs iguais para ter um voo de multi-UAVs, porém não houve tempo de conseguir um novo gimbal para realizar mais testes das imagens e voos com um sistema embarcado de detecção em tempo real.

Por esse fato, foi necessário realizar alguns testes em simulador para validar se conseguimos utilizar essa técnica para realizar uma inspeção em linha de transmissão.



(a) Imagem de uma torre com isoladores e seus fios passando por ela.



(b) Imagem dos fios de alta tensão com um carro parado na área de servidão.



(c) Imagem dos fios de alta tensão passando entre duas ruas que estão em paralelo.

Figura 20 – Imagens obtida pelo voo teste realizado em um F450 em um mesmo local.  
Fonte: Próprio Autor

## 3.2 Voo em simulador e teste da inteligência artificial com imagens reais

Nos testes realizados em voo vimos uma resposta mais rápida pela biblioteca do MAVSDK, com isso foi determinado o desenvolvimento do código para navegação com essa biblioteca. Para que fosse possível testar o código desenvolvido, foi escolhido um simulador que fosse possível fazer uma simulação de ambiente real para visualização de um trajeto de inspeção com linhas, torres e uma área de servidão debaixo da linha.

Entre alguns simuladores, foi realizado uma pesquisa onde teria uma simulação mais perto com a real e o simulador que deu mais destaque foi o AirSim, que seria um

simulador desenvolvido na plataforma da Unreal Engine que teve como foco a pesquisa de inteligência artificial, voltado para navegação autônoma de UAV e carros [RESEARCH, 2021].

Nesse simulador se utiliza uma biblioteca do AirSim mesmo que se parece muito com a MAVSDK e tem a possibilidade de se colocar múltiplos drones. Para essa pesquisa foi utilizado um mapa chamado LandscapeMountains, apresentado na Figura 21, onde nesse mapa tem linhas de transmissão de alta tensão por montanhas com o início dela sendo em uma subestação.




Figura 21 – Imagens do simulador com mapa utilizado. Fonte: Próprio Autor

A comunicação entre os UAVs da simulação eram feitos através do MAVSDK onde para cada UAV era atribuído um IP diferente para realizar a conexão com ele.

Inicialmente foram implementados comandos autônomos onde para cada UAV eram enviadas coordenadas de latitude e longitude, diferenciando a altitude como medida de segurança, onde tinha o primeiro UAV voando a uma distância de 30 metros acima da linha, segundo UAV voando a 5 metros acima do primeiro UAV e o terceiro voando a 40 metros acima do primeiro UAV.

Na simulação podemos ver que desse modo todos podem funcionar de modo independente para cada propósito. Onde a escolha da função de cada UAV foi definido pelo que cada um vai detectar. O mais próximo da linha ficou com a detecção preventiva dos fios, pelo fato de quanto mais afastado menor é a visão das linhas, assim dificultando detectar algum problema que pode aparecer. Segundo UAV ficou de avaliar a torre de transmissão, pelo fato de que a torre ser um objeto maior, fica um pouco mais fácil de ser observado de mais longe e o terceiro UAV ficou com a função de se observar algum intruso na linha.

Para melhor teste de visualização de cada UAV, foi colocado um atraso para que cada UAV seja enviado para seu ponto inicial, assim um não atrapalhando a visualização do outro e assim evitando dar algum falso positivo nas imagens.

Um problema que temos tanto em voo real é o fato de que os cabos de alta tensão quando possuem torres muito distantes uma da outra ou em caso de terreno montanhoso, os cabos acabam fazendo um arco para baixo, ficando distante do UAV que está fazendo o monitoramento dele. Isso faz com que fique difícil para observar caso haja algum problema com os cabos. Visando tentar solucionar isso, foi proposto uma solução pelo Antônio que será apresentado a seguir.

### 3.2.0.1 Modelagem de navegação

Para que seja feita uma vistoria mais detalhada dos cabos de uma linha de alta tensão, não é possível que a distância da câmera do UAV fique muito longe dos cabos. Com isso foi proposto que se utilize dois quadrirotores, onde o principal ainda continue navegando sobre a linha e um segundo quadrirotor acompanhe na lateral da linha para que consiga acompanhar o movimento dos cabos de forma que o principal abaixe sua altitude para ter uma navegação com uma distância segura e constante dos cabos. Na figura 22 é apresentado a trajetória proposta.

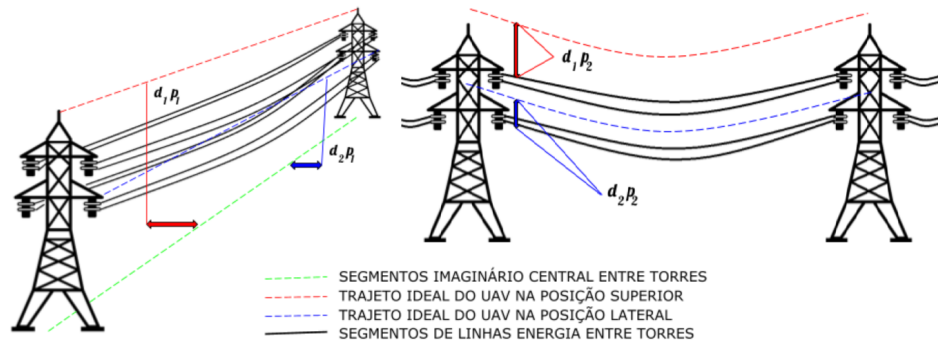


Figura 22 – Apresentação da solução proposta. Fonte:[FILHO et al., 2021]

Para compreender melhor a ideia apresentada, levamos em consideração que o  $p$  e a posição que se encontra o UAV em relação a duas ou demais torres sendo vista por um observador,  $d$  e a distância do UAV em relação a dois trajetos definidos entre duas torres tendo a medida em metros e o  $s$  e o trajeto em linha reta entre duas torres.

Tendo em vista que a trajetória definida pelo UAV que se encontra na parte superior da linha e a trajetória em linha reto do centro de uma torre a outra devem apresentar a mesma distância, pelo fato de que ele estaria no centro da linha para que possa observar todas os fios utilizados por essas torres. A equação 3.1 demonstra o rastreamento pelo centro das linhas.

$$d_1 p_1 = s_1 \quad (3.1)$$

Analisando da mesma forma o UAV que se encontra na lateral da linha, precisa estar no centro das trajetórias dos fios para que consiga observar todos os fios, com isso e

apresentado pela equação 3.2. Sendo o  $s_2$  o a distância do segmento do fio superior com o solo e  $s_3$  sendo a distância do solo com o segmento do fio inferior.

$$d_2p_2 = (s_2 - s_3)/2 \quad (3.2)$$

Para as demais distancias em que cada UAV irá utilizar durante o voo e necessário acrescentar uma constante  $c$  que representa a altitude da legislação vigente para o monitoramento de linhas seja respeitado e que possa ter uma visualização de todos os fios da linha. Na equação 3.3 e representada pela distância do UAV superior e a equação 3.4 e representada pelo UAV lateral.

$$d_2p_1 = c_1 \cdot s_1 \quad (3.3)$$

$$d_1p_2 = c_2 \cdot s_1 \quad (3.4)$$

Após a obtenção dos valores, caso seja necessário, serão feitas correções simples de movimentos. Para uma melhor orientação do UAV, deve-se utilizar um gimbal, pois o movimento sendo inconstante pode influenciar no resultado do movimento.

Os UAV poderão atuar de forma simultânea, podendo ser utilizado de forma espalhada, sendo que será possível ser utilizado quatro UAVs para que atue de forma colaborativa e com atividades independentes. Podendo desse modo também em trabalho espalhado, tendo uma cobertura mais completa de inspeção, podendo obter um maior detalhamento em pontos específicos.

Após ter implementado e testado os códigos de navegação, foi feito o treinamento da rede de detecção. Pelo fato de não se ter um dataset de possíveis problemas que possa ter na linha de transmissão ou da torre, foram treinadas as detecções dos fios e torres. Tendo também o treinamento para detecção de veículos, casa, árvores e pessoas.

### 3.2.1 Treinamento da inteligência artificial

O treinamento da rede foi feito simulando a execução em um sistema embarcado, onde o treinamento é mais rápido e com um arquivo de peso menor, tendo um pouco menos de acurácia que os outros métodos da YOLOv5, porém fazendo com que fique de com um maior FPS, os resultados são apresentados na Figura 23.

O treinamento da rede foi realizado com dois dataset diferentes, o primeiro contendo 218 imagens, onde possuía 11 classes diferentes que são elas: cabo, poste, isolador, casa, carro, construção, torre, árvore, pessoa, caminhão e galpão. Foi criado um segundo dataset onde possuía 2243 imagens, com isso foi feito um treinamento para se comparar

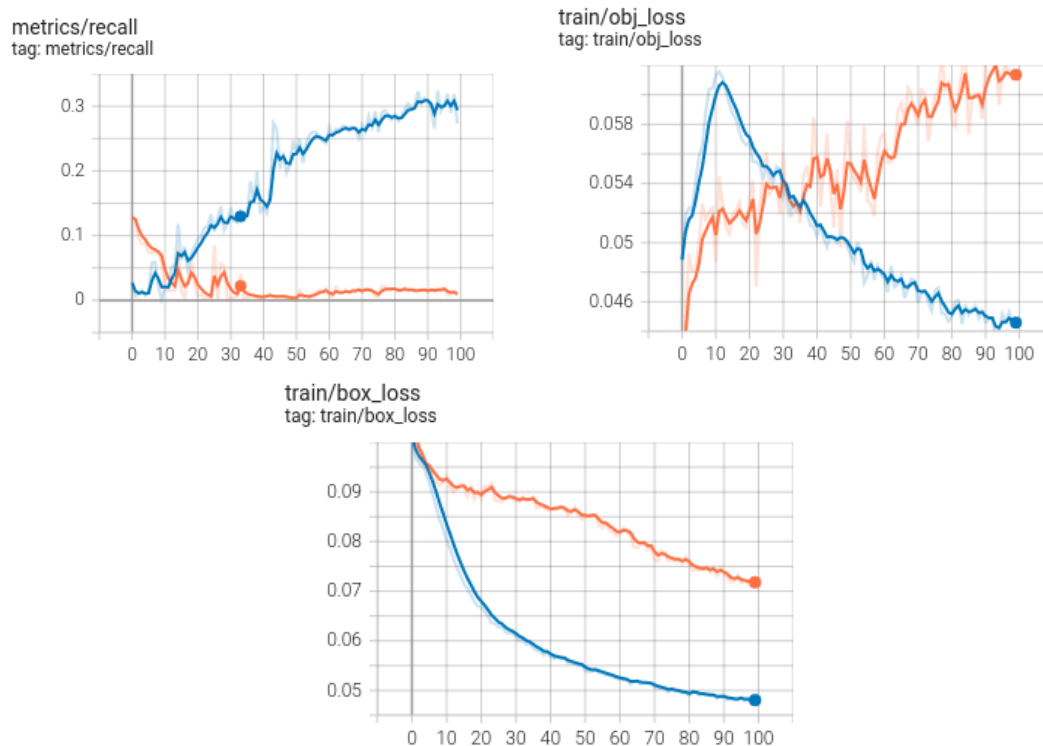


Figura 23 – Comparação de treinamento com 100 épocas de um dataset com linha azul com 218 imagens e laranja é um dataset de 2243 imagens.

Classes	Dataset 218	Dataset 2243
Cabo	782	19990
Poste	131	721
Isolador	112	778
Casa	92	186
Carro	76	95
Construção	38	67
Torre	38	1251
Árvore	32	59
Pessoa	23	32
Caminhão	12	23
Galpão	12	31

Tabela 2 – Quantidade de marcação das classes em cada dataset.

como se comporta a rede com diferentes quantidades de imagem. Posteriormente foi treinado o dataset com 218 imagens com 1000 épocas. Na tabela 2 é apresentada a quantidade de marcações de cada classe que possui em cada dataset.

Fazendo uma análise no gráfico da Figura 23, podemos ver que o dataset com menor quantidade de imagem possui uma perda menor nas imagens de objeto, enquanto que no dataset com maior quantidade com 100 épocas se comporta com uma quantidade de perda dos objetos muito mais alto.

Isso motivou a utilização do dataset menor para ser utilizado em um primeiro

momento, segundo motivo foi pelo fato de que o treinamento feito com um dataset menor é mais rápido e fica com um arquivo onde possui os pesos menor que acaba beneficiando para utilização em um sistema embarcado.

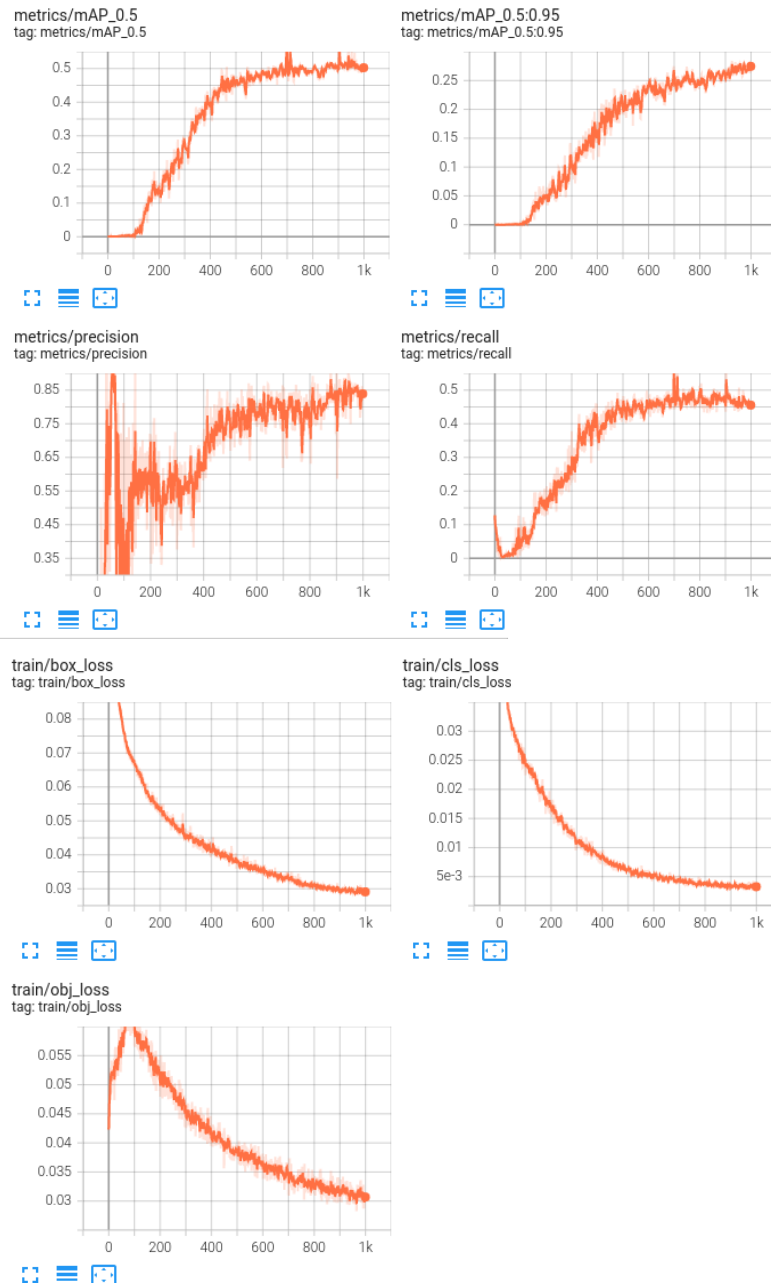


Figura 24 – Gráficos apresentando resultado do treinamento feito com a rede YOLOv5.

Analisado os gráficos apresentados na figura 24 podemos ver que quanto mais épocas treinadas, mais a precisão da rede. Conseguindo assim ter uma acurácia de 75% onde para uma detecção em tempo real com FPS alto é aceitável.

Após a conclusão do treinamento da rede, os pesos obtidos foram utilizados para fazer a detecção em 14 vídeos e 50 imagens que não se encontravam no dataset de treinamento, porém da mesma região de treinamento e foi possível obter as imagens da figura

25. Nessas imagens temos no a as imagens sem que tenha sido feito a detecção e na b vemos as imagens com as detecções feitas.



(a) Imagens de uma região com linha de alta tensão sem o processamento da rede neural.



(b) Imagens da mesma região onde temos identificação de linhas de transmissão, poste, torre, carro, pessoa, casa e construção.

Figura 25 – Imagens coletadas de um voo utilizando DJI Mavic e depois que executou a rede Yolov5. Fonte: Próprio Autor

Foi realizado outro treinamento com um dataset de 2463 imagens, onde foi treinado com 100 épocas. A acurácia desse treinamento se manteve o mesmo que com 1000 épocas do outro dataset tendo 75%, que é bem aceitável.

Devido a legislação, o voo sobre linha de alta tensão tem que ser a 30 metros da linha, porém ao realizar imagens dessa distância com a câmera que foi proposta, vemos que os fios ficam muito distantes e por causa do reflexo do sol muitas vezes ele fica branco,

fazendo com que a rede Yolov5 tenha dificuldade de detectar o fio, sendo assim ele só pega muito bem objetos maiores como a torre, carro ou casa.

Foi realizado treinamento com pesos diferentes para ser utilizado em cada UAV, porém o tempo de processamento para detectar uma linha ou mais de uma classe na imagem dá uma diferença de 2 frames por segundo e o grande problema é que gera muito falso positivo.

A rede foi rodada em imagens reais de UAV, feito com MAVIC Pro. Por ser um UAV comercial e de valor elevado então não foi levado em consideração nos experimentos. Porém as imagens foram ideais para testes da rede neural para ver sua eficiência em momentos reais.

Os testes da rede neural foi realizado em dezoito vídeos obtidos durante os voos, em diferentes momentos, esses vídeos utilizados no teste no participaram do treinamento da rede neural para que fosse possível analisar a detecção dos objetos.

Algumas imagens que foram realizados mais próximo da linha, vemos que a rede Yolov5 se sai muito bem na detecção.

## 4 Conclusão

Como conclusão para o trabalho será feito um resumo de todo o trabalho, uma discussão sobre os objetivos específicos apresentado, os trabalhos futuros para essa pesquisa e as considerações finais do trabalho.

Essa dissertação teve como objetivo apresentar a possibilidade de utilização de três drones quadrirotores para realizar inspeção de forma independente onde cada um teria foco em uma parte da inspeção, utilizando inteligência artificial para análise das imagens obtidas.

Para obtenção de resultados esse trabalho teve que passar por alguns experimentos tanto em voos reais como em algumas formas simuladas.

Foi necessário realizar uma pesquisa no mercado para entender como funciona um drone, seus principais componentes para que funcione de forma autônoma. Após obtenção das informações foram feitos testes para poder saber qual melhor atenderia as necessidades desse trabalho, antes disso teve um estudo realizado sobre utilização de cada tipo de drones, para que se escolhesse o melhor que acabou sendo definido um quadrirotor construídos em laboratório.

Após a construção do drone foram realizados inúmeros voos para testar equipamentos, ver o quanto de manutenção iria precisar um drone de baixo custo e se atenderia as necessidades para se realizar um voo autônomo.

Com os drones montados, passamos para o simulador onde já havia conhecimento de funcionamento então foi feito um estudo de como realizar controle de múltiplos drones e que biblioteca mais corresponderia às necessidades do trabalho.

Com o desenvolvimento do código onde os drones já realizavam voos de forma autônoma através de waypoints, foi iniciado a pesquisa sobre inteligências artificiais que estavam no estado da arte.

Dentro das mais utilizadas foi destacada a Yolov5, desenvolvido para rodar em dispositivos com pouco poder de processamento e a maior vantagem apresentada dessa técnica é que ela consegue realizar detecção em 3 planos. O primeiro plano é o mais próximo da imagem, segundo a média distância e terceiro a uma longa distância. Demonstrando que não era necessário fazer treinamento com diversas imagens com diversas distancias para conseguir detectar os objetos.

Com a escolha da inteligência artificial foi determinado um dataset, onde 40% dele foi com imagens obtidas em campo, a partir de um Mavic Pro da DJI. Onde as imagens coletadas foram obtidas obedecendo a legislação.

Com a rede já treinada, foram feitas imagens com voos reais utilizando o MAVIC para testar seu funcionamento e constatou-se ser muito eficiente, chegando a detectar 75% dos objetos apresentados, fazendo perder apenas imagens onde os fios quase não apareciam na imagem por estarem muito brancos.

Através do treinamento conseguimos concluir que quanto mais épocas no treinamento da rede, maior é a precisão na detecção da imagem.

Foi tentado obter algumas imagens com o drone montado no laboratório, porém tivemos alguns problemas com mal funcionamento de gimbal e até mesmo houve uma queda no drone pelo fato de que durante o voo houve uma rajada de vento muito forte onde acabou escapando o GPS.

Apesar de algumas dificuldades apresentadas durante o trabalho, conseguimos concluir que é possível que se faça voo-o com múltiplos drones para inspeção de uma linha utilizando as torres como waypoints e mantendo prioridades de altitude de voo. Algumas melhorias para cada drone devem ser feitas para que seja mais viável a utilização, onde está listado a seguir.

1. Primeiro drone que faz a inspeção da linha teria que estar mais próximo a ela, para ter uma imagem mais detalhada e nítida.
2. Segundo drone que inspeciona a torre seria o do meio, podendo ter uma distância um pouco maior, pelo fato de que uma torre seja um objeto maior para se detectar.
3. Terceiro drone fica responsável pela visualização da linha de servidão que seria uma faixa maior de distância e os objetos a ser detectados são bem maiores.

Nesse trabalho vemos que no futuro podemos ter muito mais drones sendo utilizados em trabalhos como inspeção de forma autônoma. Ou até mesmo sendo utilizado para outros tipos de serviços onde múltiplos drones os tornem mais rápido, como por exemplo, localizar pessoas perdidas em florestas ou até para localização de possíveis problemas que podem se encontrar em um ambiente amplo.

## 4.1 Discussões

Os experimentos realizados nesse trabalho foram divididos em etapas para que consiga avaliar os objetivos específicos. Nessa seção será feito a discussão dos resultados obtidos para cada objetivo apresentado.

### 4.1.1 Analisar algoritmos atuais de identificação de objetos que tenham capacidade para operar embarcados em drones

Com as redes convolucionais em alta não é difícil de encontrar trabalho sendo realizado utilizando esses tipos de redes, com isso temos hoje uma grande evolução nesse cenário tendo cada vez mais redes eficientes e rápidas.

Nesse trabalho houve um profundo estudo das principais redes e suas diferenças. Observando principalmente a possibilidade de utilizar em hardware de sistemas embarcados e que possa fazer a detecção de forma rápida com a câmera variando em diferentes distancias. Com os requisitos da rede estipulado foi encontrado a rede [YOLOv5](#) que atende o que precisamos.

No processo de treinamento da rede, é feito a extração das imagens em três diferentes pontos, com isso o objeto é identificado com diferentes distancia de imagens e a rede [YOLOv5](#) possui um treinamento pequeno onde não é tão preciso porem possui uma detecção rápida em computadores embarcados.

Nos testes realizados vemos que é possível utilizar a rede embarcado pelo fato de que visualizando os vídeos onde a rede foi executada, a quantidade de objetos perdidos foram baixos, mesmo variando a altitude de voo, pois nas áreas de catenária do fio, vemos que mesmo assim ele detecta os cabos.

### 4.1.2 Montar drones que possam fazer voos autônomos de forma segura e funcional

No trabalho foi feito a comparação entre dois drones, um montado no laboratório e outro comercial.

O drone montado no laboratório, que é do modelo F450, demonstrou ser um drone que atende os requisitos para voo autônomo, porem para que ele seja feito de forma eficiente possui a necessidade de realizar uma calibragem muito rigorosa e que todas as peças sejam de boa qualidade. O que impossibilitou de utilizar esse drone foi pelo fato de ter apresentado um problema na calibragem do gimbal que acabou tendo problema de percurso e assim fazendo as imagens obtidas não fosse boa o suficiente para ser utilizada.

No caso do drone comercial, um DJI Mavic Pro Platinum, ele já vem montado de forma que precisa apenas de ligar e voar, no caso de solicitado a calibragem do mesmo é realizado de forma simples, pelo fato da empresa garantir que ele voe com uma maior estabilidade.

Em ambos os drones é possível realizar voos autônomos configurados na estação de solo, porém no drone comercial não possui a possibilidade de se ter um computador embarcado para comunicar com a controladora e assim fazer o uso da inteligência artificial

em voo. Nesse caso é necessário que o processamento seja feito posteriormente na estação de solo.

No voo realizado com Mavic, obtivemos todas as imagens que foram utilizados nesse trabalho, pois já possui uma câmera de alta qualidade e um gimbal bem estável.

Com isso conseguimos concluir que ainda estamos longe de conseguir montar um drone que fique tão estável quanto um comercial.

#### 4.1.3 Utilizar um simulador que possa ser o mais parecido com o real para realizar testes de códigos desenvolvidos de modo que fique fácil a portabilidade para voos com drones reais

Dentre os simuladores que temos atualmente para utilização nesse segmento, foi escolhido um que é utilizado para fazer teste de códigos desenvolvidos para carros autônomos e posteriormente adaptaram para quadrirotores. Esse simulador é conhecido por Airsim, onde utiliza da ferramenta Unreal Engine para criação da parte gráfica do simulador.

O código desenvolvido utilizando biblioteca do airsim é muito parecido com a biblioteca MAVSDK, onde a portabilidade para se utilizar em um drone real é muito simples, basta trocar algumas chamadas de biblioteca que já consegue ser compatível com o drone F450 que utiliza uma pixhawk como controladora.

Durante a pesquisa foi desenvolvido um código simples de navegação onde o drone iria de uma área A para uma área B. O código desenvolvido no simulador utilizando Airsim foi convertido para biblioteca do MAVSDK e o teste foi feito através de envio do comando pela telemetria que estava conectada a uma estação de solo.

Toda a navegação realizada tanto no simulador como no drone real foram feitos de maneira muito semelhantes, mesmo tendo no real o efeito do vento, onde no simulador foi executado sem nenhum tipo de interferência da natureza.

#### 4.1.4 Desenvolver um algoritmo de controle para que possa ser embarcado nos diferentes drones

Todo o desenvolvimento do código utilizado no drone foi desenvolvido pensando no menor consumo de memória pela controladora, onde o maior consumo do sistema embarcado poderia ficar na identificação de objetos.

Com isso foi focado na navegação por missão, onde é estipulado os pontos em que o drone terá que passar durante a navegação. No código de controle é criado um vetor com todos os pontos que possui uma torre e passados alguns parâmetros de altitude que

esse drone terá no ponto desejado. Com isso é enviado a informação para controladora e o código de controle fica esperando a finalização da missão.

No caso de outros tipos de algoritmos que poderiam ser desenvolvidos para navegação faria com que o código tivesse uma interação maior com a controladora, fazendo aumentar o consumo de memória do computador de bordo e assim podendo gerar um gargalo para todo o sistema.

Pensando no MAVIC, não é possível fazer um código em sistema embarcado para poder fazer a navegação pela linha de alta tensão, porém tendo os pontos de latitude e longitude é possível criar a missão através da estação de solo onde ele executaria a missão do mesmo modo que o F450 através do código embarcado.

#### 4.1.5 Conseguir realizar um comparativo das capacidades do simulador com o drone real

Com o avanço do simulador, vemos uma similaridade muito grande com o real. No drone não é muito diferente, se realizando a calibragem correta durante a montagem é possível ter um voo idêntico ao do simulador.

A tendencia é cada vez temos um simulador mais parecido com o real para poder ser desenvolvido todo o algoritmo sem ter risco de se estragar o equipamento físico.

Durante os testes, o único problema obtido foi por questão de interação da natureza durante os testes reais, onde toda a simulação realizada não possuía vento fortes e na hora do voo real aconteceu de ter uma rajada de vento que acabou levando o F450 a cair, porém por problemas estruturais e não do código desenvolvido no simulador.

## 4.2 Trabalhos Futuros

Para uma complementação do trabalho realizado, sugere-se os seguintes trabalhos futuros:

- Acrescentar no dataset imagens onde se possui possível defeitos que podem ser tratados preventivamente.
- Montagem de um possível gimbal para estabilização da câmera e um voo com imagens mais próximas das linhas de transmissão para que haja imagens mais detalhadas de cada classe onde resolveria o problema dos cabos brancos e imagens tremidas.
- Embarcar o código para que seja feito de forma automática no drone a detecção e com uma Raspberry Pi seja possível realizar voos de múltiplos drones.

### 4.3 Considerações Finais

Houve um grande desafio desde o início desse trabalho, mas que durante o desenvolvimento, foi possível observar o grande potencial que um drone pode ter em atividades comuns do dia a dia. Utilizando a visão computacional, não só na área pesquisada, porém em muitas outras podem aproveitar dessas mesmas técnicas para que seja usado essa ferramenta a seu favor.

# Referências

- ALI, F. Building a spin coater device for thin-film preparation. In: IOP PUBLISHING. *IOP Conference Series: Materials Science and Engineering*. [S.l.], 2020. v. 757, n. 1, p. 012050. 9, 27
- BARCIŚ, A.; BARCIŚ, M.; BETTSTETTER, C. Robots that sync and swarm: A proof of concept in ros 2. In: IEEE. *2019 International Symposium on Multi-Robot and Multi-Agent Systems (MRS)*. [S.l.], 2019. p. 98–104. 21
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*, 2020. 9, 32
- BOON, M.; DRIJFHOUT, A.; TESFAMICHAEL, S. Comparison of a fixed-wing and multi-rotor uav for environmental mapping applications: A case study. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Copernicus GmbH, v. 42, p. 47, 2017. 23
- CIOBANU, E. *What Are GPS Drones, and Why Does It Matter*. 2022. <<https://www.droneblog.com/what-are-gps-drones-and-why-does-it-matter/>>. 27
- DANTAS, A. et al. Intelligent system for detection and identification of ground anomalies for rescue. In: SPRINGER NATURE. *ITNG 2022 19th International Conference on Information Technology-New Generations*. [S.l.]. p. 277. 16
- \_\_\_\_\_. Low-cost uav for medical delivery. 16
- \_\_\_\_\_. Using uav, iomt and ai for monitoring and supplying of covid-19 patients. In: SPRINGER. *ITNG 2021 18th International Conference on Information Technology-New Generations*. [S.l.], 2021. p. 383–386. 16
- DIAZ-MENDEZ, Y. et al. Conditional integrator sliding mode control of an unmanned quadrotor helicopter. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, SAGE Publications Sage UK: London, England, v. 236, n. 3, p. 458–472, 2022. 16
- DJI. *Naza-M Lite*. <<https://www.dji.com/naza-m-lite>>. 9, 24
- DWIVEDI, P. *YOLOv5 compared to Faster RCNN. Who wins?* 2020. <<https://towardsdatascience.com/yolov5-compared-to-faster-rcnn-who-wins-a771cd6c9fb4>>. 30
- FILHO, A. J. D. et al. Algoritmos de processamento digital de imagens para rastreamento de linhas de transmissão de energia. Universidade Federal de Itajubá, 2021. 9, 40
- \_\_\_\_\_. A general low cost uav solution for power line tracking. In: SPRINGER NATURE. *17th International Conference on Information Technology–New Generations (ITNG 2020)*. [S.l.], 2020. v. 1134, p. 525. 16
- FOUNDATION, D. *MAVSDK*. 2021. <<https://mavsdk.mavlink.io/main/en/index.html>>. 22, 37

- FOUNDATION, O. S. R. *Gazebo*. 2014. <<http://gazebo.org/>>. 19
- GIANOTTO, J. *Acidente com helicóptero que bateu em fios e afundou em açude é investigado*. 2022. <<https://aeroin.net/acidente-com-helicoptero-que-bateu-em-linha-de-transmissao-e-afundou-em-acude-e-investigado/>>. 15
- GOMES, M. C. da S. et al. The use of 5g networks to control uavs. In: *23ème congrès annuel de la Société Française de Recherche Opérationnelle et d'Aide à la Décision*. [S.l.: s.n.], 2022. 16
- INC, D. P. *QGROUNDCONTROL*. 2019. <<http://qgroundcontrol.com>>. 9, 29
- JESUS, L. D. d. et al. Greater autonomy for rpas using solar panels and taking advantage of rising winds through the algorithm. In: SPRINGER. *16th International Conference on Information Technology-New Generations (ITNG 2019)*. [S.l.], 2019. p. 615–616. 16
- JESUS, L. D. de et al. Increased autonomy for uav using solar panels and take advantage of updrafts through algorithm. 16
- JOCHER, G. *YOLOv5*. 2021. <<https://github.com/ultralytics/yolov5>>. 9, 34
- KHALIQ, S.; AHSAN, S.; NISAR, M. D. Multi-platform hardware in the loop (hil) simulation for decentralized swarm communication using ros and gazebo. In: IEEE. *2021 IEEE 22nd International Symposium on a World of Wireless, Mobile and Multimedia Networks (WoWMoM)*. [S.l.], 2021. p. 310–315. 22
- MARTINS, W. M. et al. Tracking for inspection in energy transmission power lines using unmanned aerial vehicles: a systematic review of current and specific literature. *IAES International Journal of Robotics and Automation*, IAES Institute of Advanced Engineering and Science, v. 9, n. 4, p. 233, 2020. 16
- MATHIE, C. *A diferença entre motores com e sem escovas*. 2017. <[https://www.ehow.com.br/sintomas-sensor-rotacao-defeituoso-sobre\\_32443/](https://www.ehow.com.br/sintomas-sensor-rotacao-defeituoso-sobre_32443/)>. 26
- NELSON, J. S. J. *Responding to the Controversy about YOLOv5*. 2020. <<https://blog.roboflow.com/yolov4-versus-yolov5/>>. 9, 33
- PENHA, D. D. P. et al. Rede neural convolucional aplicada à identificação de equipamentos residenciais para sistemas de monitoramento não-intrusivo de carga. *Universidade Federal do Pará*, 2018. 30
- PHADTARE, M. et al. Comparison between yolo and ssd mobile net for object detection in a surveillance drone. 2021. 17
- PROJECT, D. *MAVLink Developer Guide*. 2022. <<https://mavlink.io/en/>>. 22
- REDMON, J. et al. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 779–788. 9, 31
- REDMON, J.; FARHADI, A. Yolo9000: better, faster, stronger. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 7263–7271. 31

- \_\_\_\_\_. Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018. 32
- RESEARCH, M. *Welcome to AirSim*. 2021. <<https://microsoft.github.io/AirSim/>>. 20, 39
- RIBEIRO, L. do V. *Estudo de Algoritmos de Visão Computacional para Identificação e Rastreamento de Linhas de Transmissão de Energia Elétrica com Multirotóres*. Dissertação (Mestrado) — UNIFEI, <<https://repositorio.unifei.edu.br/xmlui/handle/123456789/2118?locale-attribute=en>>, 2019. 15
- SAMER, H.; RISHI, K.; CHRIS, R. Using convolutional neural networks for image recognition. *Cadence IP.[Online]*, 2015. 30
- SÁNCHEZ, P. et al. An approach to modeling and developing teleo-reactive systems considering timing constraints. *Journal of Systems and Software*, Elsevier, v. 117, p. 317–333, 2016. 9, 20
- SHAH, S. et al. Airsim: High-fidelity visual and physical simulation for autonomous vehicles. In: SPRINGER. *Field and service robotics*. [S.l.], 2018. p. 621–635. 9, 21
- SILVEIRA, C. B. *Motor CC: Saiba como Funciona e de que forma Especificar*. 2016. <<https://www.citisystems.com.br/motor-cc/>>. 9, 27
- TEAM, A. D. *Mission Planner Overview*. <<https://ardupilot.org/planner/docs/mission-planner-overview.html>>. 9, 30
- \_\_\_\_\_. *Archived:APM 2.5 and 2.6 Overview*. 2021. <<https://ardupilot.org/copter/docs/common-apm25-and-26-overview.html>>. 9, 24, 25
- \_\_\_\_\_. *History of ArduPilot*. 2021. <<https://ardupilot.org/copter/docs/common-history-of-ardupilot.html>>. 24, 25
- \_\_\_\_\_. *Pixhawk Overview*. 2021. <<https://ardupilot.org/copter/docs/common-pixhawk-overview.html>>. 9, 25
- THUAN, D. Evolution of yolo algorithm and yolov5: the state-of-the-art object detection algorithm. 2021. 32
- VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: SN. *Proceedings of the xxix conference on graphics, patterns and images*. [S.l.], 2016. v. 1, n. 4. 9, 31
- WU, T.-H.; WANG, T.-W.; LIU, Y.-Q. Real-time vehicle and distance detection based on improved yolo v5 network. In: IEEE. *2021 3rd World Symposium on Artificial Intelligence (WSAI)*. [S.l.], 2021. p. 24–28. 17
- ZHOU, J. et al. Ship target detection algorithm based on improved yolov5. *Journal of Marine Science and Engineering*, Multidisciplinary Digital Publishing Institute, v. 9, n. 8, p. 908, 2021. 17