

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Guilherme Augusto Namorato Pussente

**Método de estimativa de trajetória para seguimento de linhas de transmissão
através de veículos multirrotores**

Juiz de Fora

2022

Guilherme Augusto Namorato Pussente

**Método de estimativa de trajetória para seguimento de linhas de transmissão
através de veículos multirrotores**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos

Orientador: Dr.Eng. Eduardo Pestana de Aguiar

Coorientador: Dr.Eng. André Luís Marques Marcato

Juiz de Fora

2022

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Pussente, Guilherme Augusto Namorato.

Método de estimativa de trajetória para seguimento de linhas de transmissão através de veículos multirrotores / Guilherme Augusto Namorato Pussente. – 2022.

79 f. : il.

Orientador: Eduardo Pestana de Aguiar

Coorientador: André Luís Marques Marcato

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2022.

1. VANT. 2. Linhas de Transmissão. 3. Visão Computacional. I. Aguiar, Eduardo Pestana , orient. II. Marcato, André Luís , coorient. III. Título.

Guilherme Augusto Namorato Pussente

Método de estimativa de trajetória para seguimento de linhas de transmissão através de veículos multirrotores

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos

Aprovada em 22 de fevereiro de 2022.

BANCA EXAMINADORA

Prof. Dr. Eduardo Pestana de Aguiar - Orientador

Universidade Federal de Juiz de Fora

Prof. Dr. André Luís Marques Marcato

Universidade Federal de Juiz de Fora

Profa. Dra. Milena Faria Pinto

Centro Federal de Educação Tecnológica Celso Suckow da Fonseca

Prof. Dr. Alexandre Bessa dos Santos

Universidade Federal de Juiz de Fora

Juiz de Fora, 07/02/2022.



Documento assinado eletronicamente por **Milena Faria Pinto, Usuário Externo**, em 22/02/2022, às 11:05, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Andre Luis Marques Marcato, Professor(a)**, em 22/02/2022, às 11:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alexandre Bessa dos Santos, Professor(a)**, em 22/02/2022, às 11:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Eduardo Pestana de Aguiar, Professor(a)**, em 22/02/2022, às 11:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **0669856** e o código CRC **3408D415**.

AGRADECIMENTOS

Eu dedico este trabalho primeiramente à toda minha família, em especial aos meus pais Agostinho e Valéria pelo apoio incondicional durante toda minha caminhada até este momento. Agradeço também aos meus amigos do IF SUDESTE MG e da comunidade Camps Central do Brasfoot (CCB) pelo companheirismo e pelos momentos de descontração, ao meu companheiro de pesquisa Tiago Santa Maria pelas diversas discussões acerca do estudo apresentado nesta dissertação. Gostaria de agradecer também aos meus orientadores Eduardo Aguiar e André Marcato pelos conselhos, direcionamentos e pela confiança depositada. Por fim, eu agradeço às agências de apoio à pesquisa CAPES e CNPq pelo aporte financeiro crucial para o desenvolvimento das pesquisas realizadas e a Universidade Federal de Juiz de Fora, em especial ao Programa de Pós-Graduação Strictu Sensu em Engenharia Elétrica pela oportunidade e pela infraestrutura concedida.

RESUMO

A inspeção de linhas de transmissão é uma das diversas áreas que vem sendo beneficiada pelo advento dos Veículos aéreos não tripulados (VANTs) que, por características como mobilidade e flexibilidade, propiciam vantagens em relação a inspeções manuais e veículos terrestres. Uma das etapas nesta tarefa é a determinação da trajetória a ser executada pelo VANT e desta forma, esta dissertação busca apresentar um método de seguimento de linhas de transmissão como um planejamento de trajetória local. Inicialmente, as imagens obtidas por câmeras acopladas ao VANT são tratadas e as linhas são detectadas por um detector genérico que não distingue linhas de transmissão em relação a outros elementos retilíneos. Em seguida, um método de ajuste de curvas é empregado visando mitigar o efeito das linhas espúrias e determinar a trajetória com o objetivo de mantê-la no centro das linhas. Testes foram conduzidos e a melhor combinação de técnicas para a detecção das linhas levando em conta as taxas de precisão, acurácia e tempo de execução foi o método Canny + Transformada de Hough Kernelizada (KHT). Para o ajuste de curvas o método que mais aproximou a trajetória à reta esperada foi o algoritmo RANSAC (do inglês, *Random Sample Consensus*). Testes práticos envolvendo a metodologia apresentada com um controlador do tipo NMPC (do inglês, *Non-Linear Model Predictive Control*) foram realizados em um ambiente interno mostrando que o VANT conseguiu realizar o seguimento das linhas de acordo com as restrições impostas. Experimentos envolvendo o cálculo da trajetória em ambientes reais foram realizados sem a integração do controlador e os resultados mostram que a estimação foi coerente na grande parte dos *frames*.

Palavras chave : VANT. Linhas de transmissão. Visão computacional.

ABSTRACT

The inspection of power lines is one of several areas that have been benefited from the advent of Unmanned Aerial Vehicles (UAVs) that, due to characteristics such as mobility and flexibility, provide advantages over manual inspections and ground vehicles. One of the steps in this task is the determination of the trajectory to be performed by the UAV and thus, this work aims to introduce a method to power lines path following as a local trajectory planning. Initially, the images obtained by cameras attached to the UAV are processed and the lines are detected by a generic detector that does not distinguish power lines from other rectilinear elements. Then a curve fitting method is employed to mitigate the effect of spurious lines and determine the trajectory with the purpose of keeping it in the center of the lines. Tests were conducted and the best combination of techniques for line detection taking into account accuracy rates, precision and execution time was the Canny + Kernelized Hough Transform (KHT) method. For curve fitting the method that best approximated the trajectory to the expected straight line was the RANSAC algorithm. Practical tests involving the proposed methodology with an NMPC controller were performed in an indoor environment showing that the UAV was able to follow the lines according to the imposed constraints. Experiments involving the calculation of the path in real environments were performed with no controller integration and the results show that the estimation was consistent in most of the frames.

Keywords : UAV. Power lines. Computer Vision.

LISTA DE ILUSTRAÇÕES

Figura 1 – Configurações de VANTs. Fonte: aerodronebrasil.com	17
Figura 2 – Topologia de VANTs de asa rotativa. Fonte: (ANWEILER; PIWOWARSKI, 2017)	17
Figura 3 – VANT com pulverizador de pesticidas. Fonte: (RAO; RAO, 2019)	18
Figura 4 – Entrega de encomendas por meio de VANT. Fonte: forbes.com	19
Figura 5 – Falhas nos sistemas de transmissão. Fonte: (POULIOT; RICHARD; MONTAMBAULT, 2015).	20
Figura 6 – Exemplos de técnicas de inspeção em linhas de transmissão. Fonte: (ALHASSAN et al., 2020)	24
Figura 7 – Operador humano sendo auxiliado por VANT. Fonte: (UZAKOV; NASCIMENTO; SASKA, 2020)	25
Figura 8 – Interface gráfica para inspeção de linhas de transmissão. Fonte: (TAKAYA et al., 2019)	26
Figura 9 – Processo de alinhamento e seguimento. Fonte: (CERÓN; MONDRAGÓN; PRIETO, 2018)	27
Figura 10 – Exemplo da aplicação da Transformada de Hough. Fonte: (SHUAI et al., 2017)	28
Figura 11 – Exemplo da Transformada de Hough. Fonte: do autor	29
Figura 12 – Estrutura do sistema de detecção baseado em CNN. Fonte: (ZHANG et al., 2019)	30
Figura 13 – Estrutura de um neurônio de uma PCNN. Fonte: (FORGÁČ; MOKRIŠ, 2005)	32
Figura 14 – Saída de uma PCNN para diferentes iterações. Fonte: (LI et al., 2010)	32
Figura 15 – Agrupamento de <i>pixels</i> em regiões com ângulo de gradiente semelhantes. Fonte: (GIOI et al., 2012)	33
Figura 16 – Princípio de um controle MPC. Fonte: (FINDEISEN; ALLGÖWER, 2002)	35
Figura 17 – VANT sobrevoando objetos detectados por uma câmera. Fonte: (FALLANGA et al., 2018)	38
Figura 18 – Estrutura de um controlador PID clássico. Fonte: (KUMAR; NAKRA; MITTAL, 2011)	39
Figura 19 – Representação da etapa de classificação de <i>inliers/outliers</i> . Fonte: do autor.	42
Figura 20 – Comparação dos métodos de Ajuste de Curvas. Os pontos em roxo indicam as amostras que fazem parte do modelo enquanto os pontos em verde são amostras ruidosas Fonte: do autor.	44

Figura 21 – Diagrama das etapas referentes a metodologia proposta. Fonte: do autor.	46
Figura 22 – Exemplos de referências adotadas em imagens de linhas de transmissão. Fonte: (ZHANG et al., 2019).	47
Figura 23 – Vistas do problema proposto. Fonte: do autor.	49
Figura 24 – Transformação do espaço de cores. Fonte: do autor.	52
Figura 25 – Processo de Desfoque Gaussiano. Fonte: do autor.	52
Figura 26 – Aplicação do Operador Sobel. Fonte: do autor.	53
Figura 27 – Detector de Bordas Canny. Fonte: do autor.	53
Figura 28 – Diagrama do Processamento de Imagem. Fonte: do autor.	54
Figura 29 – Aplicação da Transformada de Hough. Fonte: do autor.	55
Figura 30 – Ajuste de Modelo: Método RANSAC. Fonte: do autor.	55
Figura 31 – Representação gráfica do fluxo de dados do algoritmo de controle. Fonte: do autor.	58
Figura 32 – Ajuste de Curvas - Cenário sem <i>outliers</i> . Fonte: do autor.	63
Figura 33 – Ajuste de Curvas - Cenário com <i>outliers</i> . Fonte: do autor.	64
Figura 34 – Extração das informações visuais da imagem. Fonte: do autor.	65
Figura 35 – Quadrotor DJI Tello. Fonte: amazon.com.br	66
Figura 36 – Ambiente utilizado para os testes de controle. Fonte: do autor.	66
Figura 37 – Resultado Individual - Variável Z . Fonte: do autor.	68
Figura 38 – Resultado Individual - Variável φ_r . Fonte: do autor.	69
Figura 39 – Resultado Individual - Variável U_{opt} . Fonte: do autor.	69
Figura 40 – Exemplos de detecção - Cenários reais. Fonte: do autor.	71

LISTA DE TABELAS

Tabela 1 – Comparação de trabalhos de seguimento de linhas	27
Tabela 2 – Comparação dos métodos de detecção de linhas	40
Tabela 3 – Comparação dos métodos de detecção de linhas	60
Tabela 4 – Comparação dos métodos de segmentação de imagens	60
Tabela 5 – Comparação dos métodos de ajuste de curvas sem <i>outliers</i>	61
Tabela 6 – Comparação dos métodos de ajuste de curvas com <i>outliers</i> . . .	62
Tabela 7 – Erro Médio Quadrático (MSE) e tempo médio para finalização de cada teste.	67
Tabela 8 – Integral do Erro Absoluto (IAE) e Variação Total de Controle (TV)	67

LISTA DE ABREVIATURAS E SIGLAS

VANT	Veículos Aéreo Não Tripulado
LiDAR	Light Detection And Ranging
GPS	Global Positioning System
R-CNN	Region-Based Convolutional Neural Network
KCF	Kernelized Correlation Filter
RANSAC	Random Sample Consensus
PCNF	Pulse Couple Neural Filter
KHT	Kernel-Based Hough Transform
MPC	Model Predictive Control
NMPC	Non-Linear Model Predictive Control
CNN	Redes Neurais Convolucionais
PCNN	Pulse Coupled Neural Network
PSO	Particle Swarm Optimization
LSD	Line Segment Detector
MRF	Markov Random Field Model
OCP	Optimal Control Problem
IBVS	Image-based Visual Servoing
PID	Controle Proporcional Integral e Derivativo
GA	Genetic Algorithm
SMC	Sliding Mode Control
OLS	Ordinary Least Squares
ROS	Robot Operating System
RGB	Red Green Blue
IMU	Inertial Measurement Unit
CBS	Circle-based search

PCNF Pulse Coupled Neural Filter

OpenCV Open Source Computer Vision Library

RGB Red-Green-Blue

LISTA DE SÍMBOLOS

G_x : Gradiente da imagem na direção X

G_y : Gradiente da imagem na direção Y

W : Eixo de coordenadas relacionadas ao Mundo

X_w : Eixo x do frame de coordenadas W

Y_w : Eixo y do frame de coordenadas W

Z_w : Eixo z do frame de coordenadas W

R : Eixo de coordenadas relacionadas ao Robô

X_r : Eixo x do frame de coordenadas R

Y_r : Eixo y do frame de coordenadas R

Z_r : Eixo z do frame de coordenadas R

\dot{x} : Taxa de variação da posição inercial do VANT em relação ao referencial X_w

\dot{y} : Taxa de variação da posição inercial do VANT em relação ao referencial Y_w

$\dot{\varphi}$: Taxa de variação do ângulo de guinada (*yaw*) em relação ao referencial Z_w

θ : Ângulo de arfagem (*pitch*) em relação à W

φ : Ângulo de guinada (*yaw*) em relação à W

ϕ : Ângulo de rolagem (*roll*) em relação à W

u : Velocidade medida ao longo do eixo X_r em R

v : Velocidade medida ao longo do eixo Y_r em R

q : Taxa de arfagem (*pitch*) medida ao longo do eixo Y_r em R

r : Taxa de guinada (*yaw*) medida ao longo do eixo Z_r em R

T : Vetor tangente ao seguimento

N : Vetor normal ao seguimento

P_f : Ponto final

Z : Erro longitudinal do VANT com relação ao ponto P_f

φ_r : Erro angular entre o eixo longitudinal do VANT (X_r) e a tangente (T) da trajetória no ponto P_f

D : Horizonte para avaliação das variáveis de erro do problema

\dot{x}_e : Vetor de erros dos estados

C : Curvatura da trajetória

\dot{s} : Abcissa curvilínea do caminho a ser seguido

\dot{Z} : Derivada do erro lateral Z

u_{opt} : Variável de controle ótima

T_p : Horizonte de predição

T_c : Horizonte de controle

ν, χ : Conjunto de valores admissíveis para os estados e para saída

ξ : Conjunto de valores factíveis para o estado terminal

Q, R : Matrizes positivas definidas que ponderam o custo de estágio

P : Matriz positiva que pondera o custo terminal

VP : Quantidade de linhas corretamente detectadas

FP : Linhas detectadas que não correspondem a linhas de transmissão

FN : Linhas de transmissão que não foram corretamente detectadas

Total Quantidade de linhas anotadas de forma manual

n : Número de amostras

Y_i : Vetor de valores observados

\hat{Y}_i : Vetor de valores previstos

N_{img} : Número de imagens

k : Fator de conversão de *pixels* para metros

dp : Distância em *pixels* da trajetória ao centro da imagem

dx : Distância longitudinal para cálculo da inclinação da trajetória

dy : Distância latitudinal para cálculo da inclinação da trajetória

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	21
1.2	Organização do Trabalho	22
1.3	Publicações	22
2	REVISÃO BIBLIOGRÁFICA	24
2.1	INSPEÇÃO DE LINHAS DE TRANSMISSÃO	24
2.2	DETECÇÃO DAS LINHAS	27
2.2.1	Transformada de Hough	28
2.2.2	Métodos baseados em Aprendizado de Máquina	29
2.3	PRÉ-PROCESSAMENTO DA IMAGEM	30
2.3.1	Detector de Bordas <i>Canny</i>	30
2.3.2	Redes Neurais Acopladas a Pulsos (PCNN)	32
2.3.3	Detector de Segmento de Linha (LSD)	33
2.3.4	EDLines	34
2.4	CONTROLADORES	34
2.4.1	Controle Preditivo Baseado em Modelo	34
2.4.2	Controle Servo Visual Baseado na Imagem (IBVS)	37
2.4.3	Controle Proporcional Integral e Derivativo	38
2.4.4	Outras técnicas de controle	39
2.5	Ajuste de Curvas	40
2.5.1	Método dos Mínimos Quadrados	40
2.5.2	RANSAC	41
2.5.3	Regressor de Theil-Sen	43
2.5.4	Regressor de Huber	43
2.6	Conclusões	45
3	METODOLOGIA	46
3.1	Representação do problema de seguimento de linhas de transmissão	47
3.2	Tratamento da Imagem	51
3.3	Detecção das linhas	54
3.4	Ajuste de modelos aplicado ao cálculo de trajetórias	54
3.5	Controlador NMPC	56
3.6	Interface ROS	57
3.7	Conclusões	58
4	RESULTADOS E DISCUSSÕES	59
4.1	Análise quantitativa dos métodos de detecção das linhas	60
4.2	Análise quantitativa das técnicas de segmentação de linhas	60
4.3	Análise quantitativa das técnicas de ajuste de curvas	61

4.4	Testes de seguimento de linhas com o controlador NMPC	63
4.5	Testes de cálculo de trajetória - Cenários reais	70
4.6	Conclusões	70
5	CONCLUSÃO E TRABALHOS FUTUROS	72
	REFERÊNCIAS	74

1 INTRODUÇÃO

Pesquisas sobre a aplicabilidade de VANTs (Veículos Aéreos Não Tripulados) em diversas áreas têm sido amplamente difundidas no meio acadêmico, sobretudo as que buscam por sistemas autônomos capazes de realizar tarefas as quais, por décadas, foram executadas parcial ou integralmente por humanos (CHEN et al., 2021). Estes veículos possuem características notáveis como a versatilidade, possibilidade de integração de diversos sensores e atuadores, razoável autonomia e baixo custo permitindo a exploração e monitoramento de áreas de difícil acesso reduzindo assim os riscos a integridade e a saúde dos trabalhadores (CUI et al., 2017).

Os VANTs ou *drones* como são comumente referidos, podem ser divididos em duas categorias: Os de asas fixas e os de asas rotativas (multirotor). O primeiro grupo apresenta uma maior autonomia com a possibilidade voos com alta velocidade, sendo úteis no mapeamento e sensoriamento de áreas extensas (ERDELJ et al., 2019). Já o segundo possui uma maior flexibilidade de movimentos, permitindo a inspeção em ambientes congestionados por máquinas e cabos ou localidades remotas como uma usina hidrelétrica (SILVA et al., 2020).

Uma característica de interesse em veículos de asa rotativa é a topologia dos mesmos ou seja: a quantidade de rotores e o posicionamento destes no *frame* do VANT uma vez que isto impacta diretamente no modelo cinemático do sistema. A figura 1 apresenta exemplos de configurações de VANTs. A figura 2 mostra diferentes tipos de topologia para VANTs de asa rotativa.



Figura 1 – Configurações de VANTs. Fonte: aerodronebrasil.com

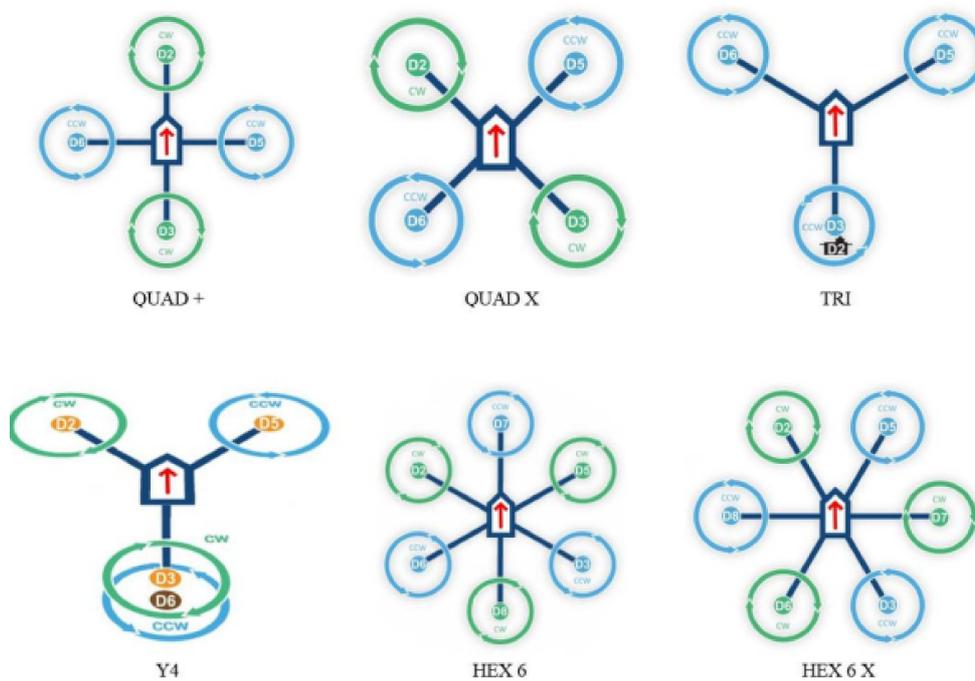


Figura 2 – Topologia de VANTs de asa rotativa. Fonte: (ANWEILER; PIWOWARSKI, 2017)

Os veículos multirotores apresentam um vasta gama de aplicações, sendo essa uma das razões para o crescimento das pesquisas na área. Na agricultura, por exemplo,

(ANTHONY et al., 2014) propõe um sistema para medição da altura de plantas através de um micro-VANT substituindo medições manuais ou equipamentos pesados que, invariavelmente, causam danos às plantas. Já (RAO; RAO, 2019) apresenta um modelo de pulverizador de pesticidas baseado em um quadrotor, mostrado na Figura 3, permitindo um maior distanciamento dos operadores com substâncias tóxicas.



Figura 3 – VANT com pulverizador de pesticidas. Fonte: (RAO; RAO, 2019)

No âmbito de sensoriamento remoto, o uso de VANTs promove inspeções mais rápidas, seguras e de maior qualidade se comparadas ao monitoramento manual. (REN et al., 2019) apresenta o uso de drones para a inspeção de áreas de mineração permitindo o monitoramento da poluição atmosférica, perigos geológicos e falhas no terreno. (BUFFI et al., 2017) emprega um quadrotor para o monitoramento de uma barragem permitindo a detecção de deslocamentos que podem evoluir para eventos catastróficos. (TOSATO et al., 2019) propõe o emprego de um conjunto de *drones* para a medição de níveis de gases, detectando possíveis vazamentos no local.

Além de aplicações industriais e agrícolas, os VANTs também podem ser empregados no meio urbano provendo melhorias em serviços como a entrega de encomendas (SAWADSITANG et al., 2018), permitindo um modelo híbrido com o uso de drones, conforme ilustrado na Figura 4, e caminhões reduzindo os custos e tempos operacionais. Outras aplicações podem envolver o auxílio ante a desastres naturais, como por exemplo, o planejamento de resgate em um cenário pós-terremoto (ZHU et al., 2019) e o monitoramento do tráfego de trânsito (ELLOUMI et al., 2018).



Figura 4 – Entrega de encomendas por meio de VANT. Fonte: forbes.com

A inspeção de linhas de transmissão é outra área que tem sido beneficiada com o advento dos VANTs e, desta forma, existe uma demanda crescente por pesquisas acerca de sistemas inteligentes que contribuam para tal tarefa (HUI et al., 2018). Características como dimensão reduzida, versatilidade e flexibilidade permitem que estes veículos auxiliem os operadores a detectarem falhas como as mostradas na Figura 5 e tomarem decisões relacionadas a manutenção do sistema com um maior distanciamento de elementos de alta tensão, reduzindo o risco de acidentes (POULIOT; RICHARD; MONTAMBAULT, 2015).

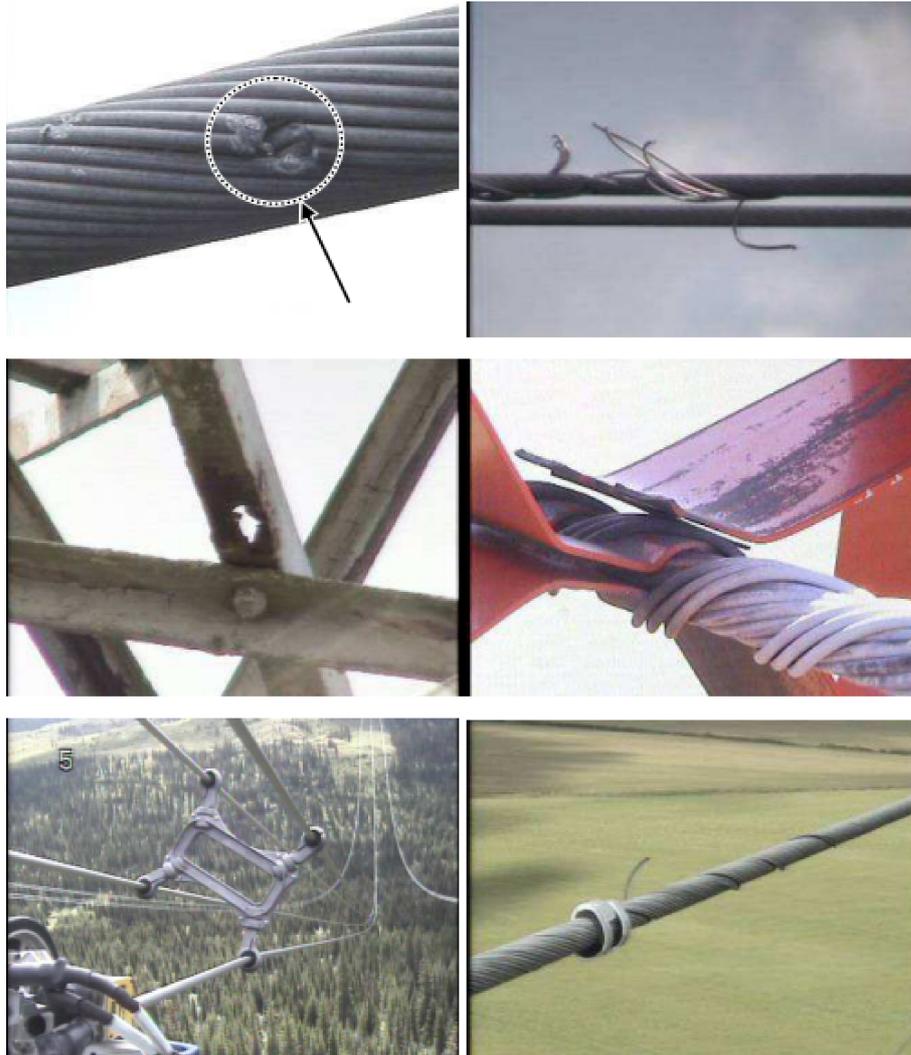


Figura 5 – Falhas nos sistemas de transmissão. Fonte: (POULIOT; RICHARD; MONTAMBAULT, 2015).

Grande parte dos trabalhos na área realizam o planejamento da trajetória para a inspeção das linhas por meio do uso de GPS concomitantemente com câmeras e sensores LiDAR (do inglês, *Light Detection And Ranging*) que nutrem algoritmos de detecção de objetos, permitindo que os VANTs sigam o trajeto mantendo certa distância de elementos como árvores e as próprias torres de transmissão (HE; ZENG; HU, 2019).

Como alternativa ao uso de GPS para o seguimento das linhas de transmissão, existem os métodos que se baseiam nas informações extraídas pelas imagens para determinação da trajetória a ser navegada. Nesta linha, (HUI et al., 2018) empregou a combinação de R-CNN (do inglês, *Region-Based Convolutional Neural Network*) com KCF (do inglês, *Kernelized Correlation Filter*) para a detecção das torres de transmissão e segmentação por aprendizado de máquina com uma filtragem posterior através do algoritmo RANSAC (do inglês, *Random sample consensus*), permitindo a extração das linhas. (LI et al., 2010)

realiza a detecção das linhas de forma rápida e robusta empregando PCNF (do inglês, *Pulse Couple Neural Filter*) para remoção de ruídos na imagem e um posterior refinamento dos resultados através da transformada KHT (do inglês, *Kernel-Based Hough Transform*).

Para o seguimento de caminhos visuais através de VANTs uma boa alternativa de controlador é o MPC (do inglês, *Model Predictive Control*) ou sua variante NMPC (do inglês, *Non-Linear Model Predictive Control*), uma vez que estes tipos de controladores são capazes de lidar com sistemas dinâmicos não lineares e multivariáveis (NASCIMENTO et al., 2019), nos quais os VANTs estão inseridos. Esta abordagem foi explorada nos trabalhos de (ALTAN; HACIOĞLU, 2020), (FALANGA et al., 2018), (ROQUE et al., 2020) e (MARIA et al., 2020). Um seguidor de linha terrestre baseado no controlador NMPC foi proposto por (RIBEIRO; CONCEIÇÃO, 2019).

1.1 Objetivos

Objetivo Principal:

- Apresentar uma metodologia para estimativa de caminhos visuais aplicado ao seguimento de linhas de transmissão.

Objetivos específicos:

- Utilizar as informações da trajetória para o controle posicional do VANT através de um planejamento local.
- Realizar testes práticos envolvendo o controle do VANT em um ambiente controlado.
- Realizar um comparativo acerca de técnicas de segmentação de imagens, detecção de linhas e ajuste de curvas.
- Testar da metodologia proposta em vídeos contendo imagens aéreas de linhas de transmissão.

Esta dissertação tem como o objetivo integrar um método de segmentação de imagens e uma técnica de detecção de linhas a um algoritmo de ajuste de curvas para resolução do problema de estimativa de caminhos visuais aplicado ao seguimento de linhas de transmissão. Informações extraídas de imagens de uma câmera acoplada ao drone foram utilizadas para a determinação da trajetória a ser seguida. Parâmetros visuais obtidos pela trajetória estimada são inseridos em um controlador NMPC que tem como objetivo calcular as ações ótimas a serem transmitidas para o VANT em uma abordagem similar apresentada por (RIBEIRO; CONCEIÇÃO, 2019) para veículos terrestres. A integração das etapas de aquisição de dados, cálculo das ações de controle e envio destas ações ao VANT foi realizada através da topologia ROS (do inglês, *Robot Operating System*).

Inicialmente, o algoritmo proposto foi testado em um ambiente controlado composto por cordas dispostas no chão simulando as linhas de transmissão que foram seguidas pelo *Drone DJI Tello*. Em seguida a detecção das linhas e estimativa da trajetória foi testada em um vídeo contendo imagens aéreas das linhas de transmissão providas pelo *Drone Parrot Bebop* controlado manualmente.

Paralelamente, foi feita uma análise comparativa de diversas metodologias empregadas para as tarefas de segmentação de imagens, detecção de linhas e ajuste de curvas aplicados ao problema de seguimento de linhas de transmissão. Esta etapa foi realizada visando um cálculo coerente da trajetória em um tempo computacional adequado às especificações de controle.

1.2 Organização do Trabalho

A presente dissertação foi organizada da seguinte forma:

- O Capítulo 2 apresenta uma revisão bibliográfica acerca dos tópicos pertinentes ao trabalho.
- O Capítulo 3 explora a formulação matemática do problema de seguimento de caminhos visuais e os passos utilizados para resolução do problema.
- O Capítulo 4 apresenta um comparativo das técnicas empregadas bem como a análise acerca de testes práticos envolvendo o seguimento de linhas.
- O Capítulo 5, por fim, apresenta uma breve conclusão dos resultados obtidos bem como sugestões para trabalhos futuros.

1.3 Publicações

Esta dissertação foi fundamentada pelos artigos publicados nos seguintes eventos:

- LARS-SBR 2020

Tiago Henrique Santa Maria, Guilherme Augusto Namorato Pussente, André Luís Marques Marcato e Eduardo Pestana de Aguiar, *Path-following problem solved by a NMPC controller applied to a UAV*, publicado nos anais do *17th IEEE Latin American Robotics Symposium - LARS 2020* e *8th Brazilian Symposium of Robotics - SBR 2020 (LARS-SBR 2020)*. - DOI: dx.doi.org/10.1109/lars/sbr/wre51543.2020.9307008

- LARS-SBR 2021

Guilherme Augusto Namorato Pussente, Tiago Henrique Santa Maria, André Luís Marques Marcato e Eduardo Pestana de Aguiar, *Trajectory Detection Method for*

Transmission Line Path Following Control, publicado nos anais do *18th IEEE Latin American Robotics Symposium - LARS 2021* e *9th Brazilian Symposium of Robotics - SBR 2021 (LARS-SBR 2021)*. - DOI: 10.1109/LARS/SBR/WRE54079.2021.9605373

A primeira publicação, realizada pelo autor Tiago Henrique Santa Maria, membro do grupo de robótica do Programa de Pós Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora apresenta o aporte para o uso do controlador NMPC para seguimento de trajetórias curvas através de VANTs. Já a segunda apresenta a metodologia proposta nesta dissertação com de forma específica para o seguimento de linhas de transmissão.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo será feita uma breve revisão dos tópicos abordados nesta dissertação, sendo apresentadas publicações científicas pertinentes ao tema proposto e um aporte teórico das técnicas utilizadas no presente trabalho.

2.1 INSPEÇÃO DE LINHAS DE TRANSMISSÃO

A inspeção das linhas de transmissão é um processo de suma importância para a manutenção da qualidade da energia elétrica entregue aos consumidores. A detecção e localização de falhas no sistema de transmissão e distribuição de energia reduzem os custos de manutenção como um todo, reduzindo possíveis cortes de energia que podem afetar severamente a economia de um país (WU et al., 2008).

Inicialmente essas inspeções eram realizadas integralmente de forma manual através do contato direto de um operador com as linhas de transmissão, por imagens obtidas por operadores situados abaixo das linhas ou com o auxílio de sensores acoplados a braços robóticos terrestres, conforme mostrado na Figura 6. Esses métodos, porém, podem trazer riscos aos operadores e ao sistema elétrico como um todo devido ao contato direto de pessoas e robôs com elementos de alta tensão. Desta forma, a utilização de VANTs se apresenta como uma alternativa viável para inspeções rápidas e não invasivas, capazes de evitar obstáculos que robôs terrestres não conseguem superar.

(UZAKOV; NASCIMENTO; SASKA, 2020) argumenta que, devido a limitações atuais dos VANTs como baixa autonomia e capacidade de carga limitada, ainda existe a necessidade da presença de trabalhadores humanos para a tarefa de manutenção da rede elétrica. Desta maneira ele propõe um sistema no qual o VANT detecta e segue um operador enquanto este realiza a manutenção do sistema facilitando o manejo das ferramentas utilizadas na operação, conforme mostrado na Figura 7.

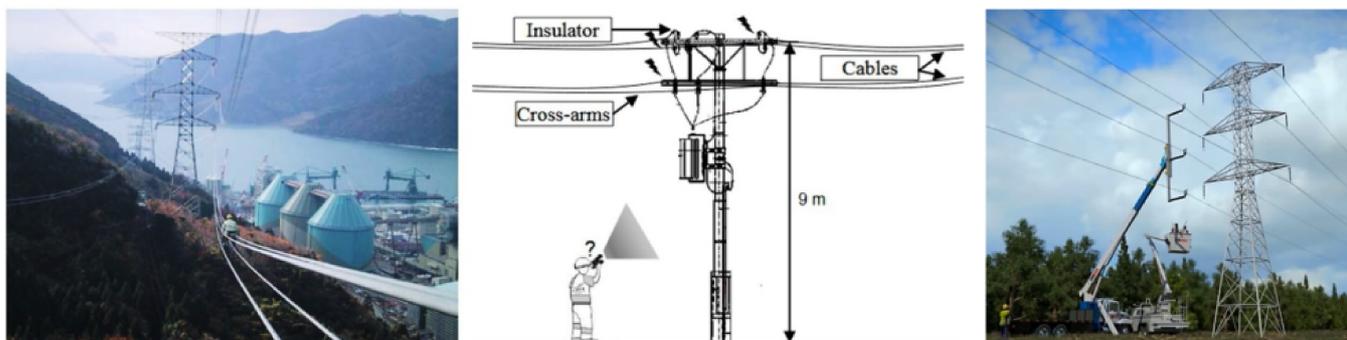


Figura 6 – Exemplos de técnicas de inspeção em linhas de transmissão. Fonte: (ALHASSAN et al., 2020)

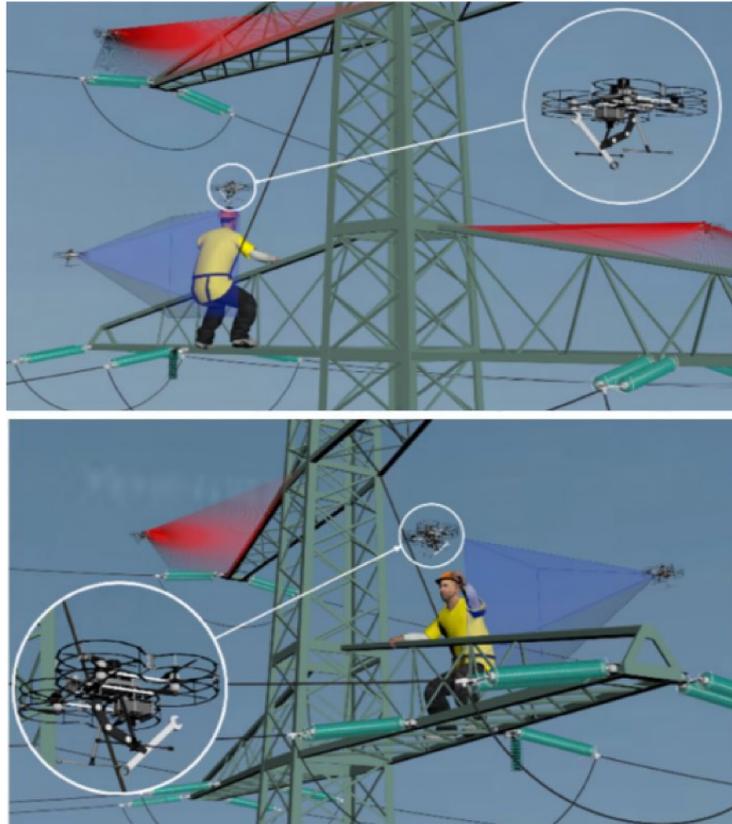


Figura 7 – Operador humano sendo auxiliado por VANT. Fonte: (UZAKOV; NASCIMENTO; SASKA, 2020)

Uma etapa importante no processo de seguimento das linhas de transmissão é a escolha da trajetória a ser realizada pelo *drone*. A abordagem proposta por esta dissertação define o planejamento da trajetória de forma local ou seja : pressupõe-se que o VANT inicia o seguimento com as linhas visíveis pela câmera ,e em seguida acontece o processo de alinhamento e posicionamento.

Uma das alternativas é a utilização de dados obtidos por GPS para escolha de pontos no espaço nos quais o VANT deve obedecer. Nesta linha, (TAKAYA et al., 2019) propõe um método para inspeção no qual o VANT decola a uma altitude segura e segue ao topo da torre de transmissão mais próxima de acordo com leituras do GPS. Em seguida, o *drone* determina a posição das linhas através de um telêmetro a laser e realiza as inspeções conforme segue a trajetória e por fim o veículo retorna a posição inicial. O processo é assistido por uma interface gráfica mostrada pela Figura 8, na qual os círculos vermelhos, azuis e verdes indicam as torres, o ponto de decolagem e as posições do VANT respectivamente. Já (JIANG et al., 2017) utiliza marcações no solo e um sistema GNSS (do inglês, *Global Navigation Satellite System*) para o georreferenciamento das linhas de transmissão para que, em seguida, seja realizada a etapa de inspeção. Estas abordagens tratam o seguimento de forma global, sem a realização de um ajuste fino que permita o

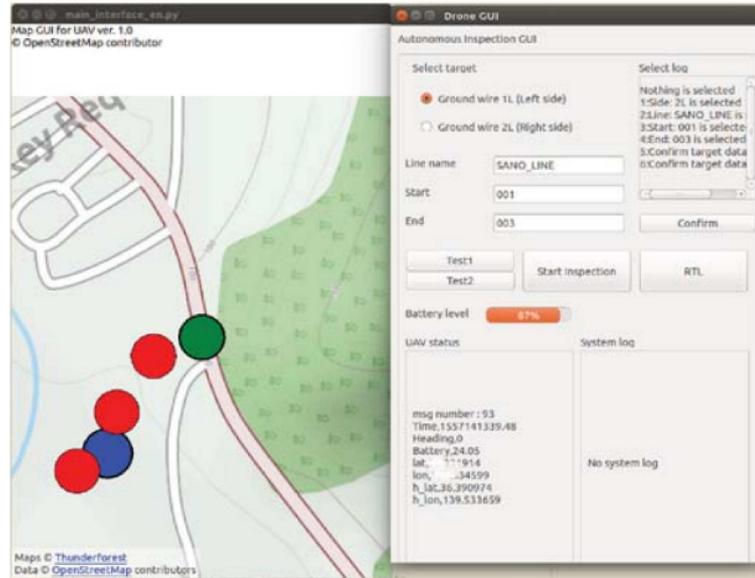


Figura 8 – Interface gráfica para inspeção de linhas de transmissão. Fonte: (TAKAYA et al., 2019)

VANT manter uma distância fixa das linhas com uma orientação definida.

Outras abordagens utilizam informações visuais obtidas pelas câmeras de forma a detectar a posição e orientação das linhas permitindo com que o veículo mantenha uma determinada distância lateral das mesmas de forma alinhada. No trabalho de (CERÓN; MONDRAGÓN; PRIETO, 2018) é proposto um sistema autônomo de detecção e seguimento no qual o *drone* decola, detecta as linhas, realiza um processo de alinhamento, e por fim, o processo de seguimento se inicia. A diferença desta abordagem para a presente dissertação se dá no método de detecção das linhas, uma vez que o autor propõe uma técnica baseada em CBS (do inglês, Circle-based search) fragmentando a detecção em blocos circulares, enquanto a abordagem deste trabalho trata as linhas de maneira integral. As etapas de alinhamento e seguimento podem ser vistas na Figura 9. Já o trabalho de (RAFIQUE; LYNCH, 2020) realiza o seguimento de linhas calculadas através do ajuste de pontos definidos através da identificação de marcações coloridas no chão. Esta abordagem se assemelha com os testes realizados nesta dissertação, diferindo-se no não tratamento de possíveis linhas espúrias. Por fim o trabalho de (DENG et al., 2016) propõe um sistema de seguimento de linhas de transmissão através da fusão de dados de um sensor LiDAR com um GPS, permitindo o seguimento levando em conta a diferença de altitude entre o VANT e as linhas.

A Tabela 1 apresenta um comparativo de trabalhos relacionados ao seguimento de linhas de transmissão, incluindo a presente dissertação. Na coluna de resultados AC indica ambiente controlado enquanto AR indica ambiente real.



Figura 9 – Processo de alinhamento e seguimento. Fonte: (CERÓN; MONDRAGÓN; PRIETO, 2018)

Tabela 1 – Comparação de trabalhos de seguimento de linhas

	Controlador	Deteccção	Tratamento de Ruídos	Resultados	Teste de estabilidade
(CERÓN; MONDRAGÓN; PRIETO, 2018)	PID	CBS	Não	Experimental em AR	Não
Presente Dissertação	NMPC	KHT	Sim	Experimental em AC	Não
(RAFIQUE; LYNCH, 2020)	PID	Máscara Binária	Não	Experimental em AC	Sim
(MARTINS et al., 2015)	Controlador não linear de dinâmica inversa	Hough	Não	Experimental em AC	Sim
(DENG et al., 2016)	PID	LiDAR	Sim	Experimental em AR	Não

2.2 DETECÇÃO DAS LINHAS

Uma etapa crucial no processo de seguimento das linhas é a deteção confiável das mesmas. Com relação aos algoritmos de classificação de objetos em imagens existem parâmetros que contribuem para avaliação da performance destes métodos. Caso o objeto seja detectado de forma correta o mesmo é chamado de verdadeiro positivo. Para o caso de não existir o objeto e o algoritmo realizar a não deteção de forma correta é dado o nome de verdadeiro negativo. Se um objeto for classificado de forma errônea este recebe o nome de falso positivo. E, por fim, caso haja um objeto não detectado pelo algoritmo este é chamado de falso negativo.

Em diversos ambientes existem elementos como marcações no asfalto, telhados e

muros de concreto que podem ser considerados como falso positivos pelos algoritmos de detecção e desta forma é necessário tratamentos para remoção destas elementos indesejados. Esta seção apresenta técnicas para detecção das linhas de transmissão.

2.2.1 Transformada de Hough

Uma das formas mais comuns de se caracterizar uma reta é a representação por coordenadas cartesianas, cuja equação básica é: $y = m * x + b$, em que m e b são os coeficientes angulares e lineares respectivamente. Embora de fácil entendimento e visualização, essa representação não é interessante para implementações computacionais tendo em vista que, para retas paralelas ao eixo das abcissas, o valor de m tende ao infinito ou é indefinido. Desta forma, uma alternativa é a utilização das coordenadas polares cujos valores são finitos para todos os tipos de retas de acordo com a equação :

$$r = x \cos(\theta) + y \sin(\theta) \quad (2.1)$$

Assim, um ponto no espaço cartesiano pode ser representado como uma linha senoidal no espaço polar. Esta senoidal indica todas as possíveis retas que passam através de um ponto (x,y) .

Para caracterização de uma reta é criado um acumulador com valores de r e θ e para cada ponto em uma imagem um conjunto de retas podem ser traçados, e desta forma o acumulador é incrementado de uma unidade ao conjunto (r,θ) correspondente. Este processo é realizado para todos os pontos e os picos do acumulador são identificados como linhas retas. A Figura 10 ilustra a mudança axial realizada pela Transformada de Hough e a Figura 11 apresenta um resultado da aplicação da transformada.

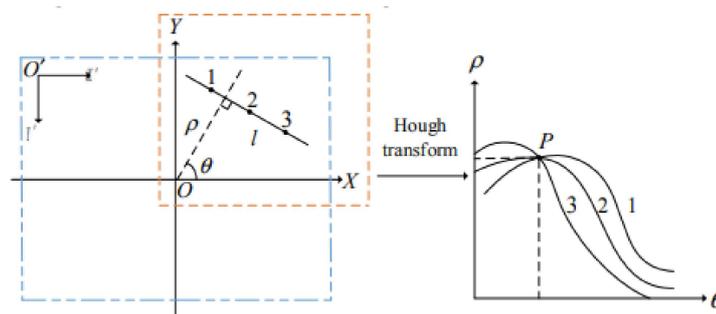


Figura 10 – Exemplo da aplicação da Transformada de Hough. Fonte: (SHUAI et al., 2017)

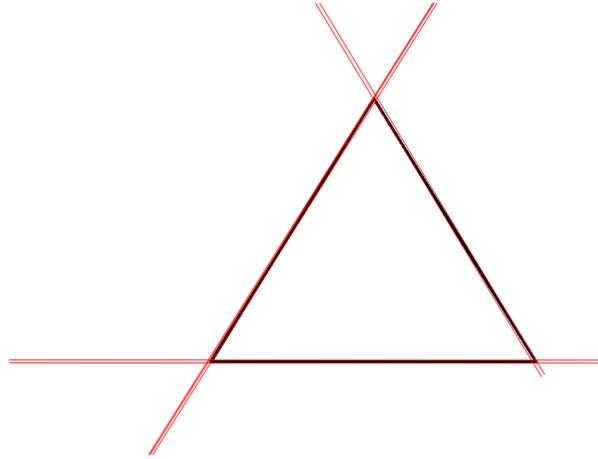


Figura 11 – Exemplo da Transformada de Hough. Fonte: do autor

Embora seja um método simples de detecção de linhas, a Transformada de Hough é bem sensível a ruídos na imagem o que gera muitos falsos positivos para a detecção de linhas de transmissão em ambientes complexos. Deste modo alguns trabalhos na literatura propõem métodos para filtrar as detecções. (ZORMPAS et al., 2018) empregou informações de *frames* prévios e a distância entre as linhas para criação de uma região de interesse e, com isso, a Transformada de Hough é aplicada apenas nas regiões delimitadas reduzindo assim o esforço computacional e minimizando a detecção de linhas espúrias. (FERNANDES; OLIVEIRA, 2008) propôs uma melhoria no processo de votação dos conjuntos de retas detectadas pela Transformada de Hough baseando-se em *clusters* de *pixels* colineares, reduzindo assim a detecção de linhas espúrias. Esta técnica que recebeu o nome de Transformada de Hough Kernelizada fora utilizada em conjunto com um filtro PCNF (do inglês, *Pulse Coupled Neural Filter* e posteriormente ao algoritmo de agrupamento *k-means* para eliminação de falsos positivos no trabalho de (LI et al., 2010). (NASSERI et al., 2018) combinou a detecção por Hough com um filtro de partículas visando uma detecção levando em conta o poder de processamento limitado de um VANT. (ZHAO et al., 2021) incorporou a Transformada de Hough clássica com Redes Neurais Convolucionais de forma a detectar linhas em ambientes complexos. As abordagens apresentadas visam aliar a Transformada de Hough com outras técnicas, de forma a distinguir linhas de Transmissão de outros elementos. A presente dissertação utiliza de uma técnica de ajuste de curvas, considerando todas as linhas detectadas, sem distinção. O intuito é determinar a trajetória de forma rápida, permitindo que o controlador atue de forma a manter o VANT alinhado as linhas.

2.2.2 Métodos baseados em Aprendizado de Máquina

Existem linhas de pesquisa que empregam métodos de Aprendizagem Profunda (do inglês, *Deep Learning*), mais especificamente Redes Neurais Convolucionais (CNNs)

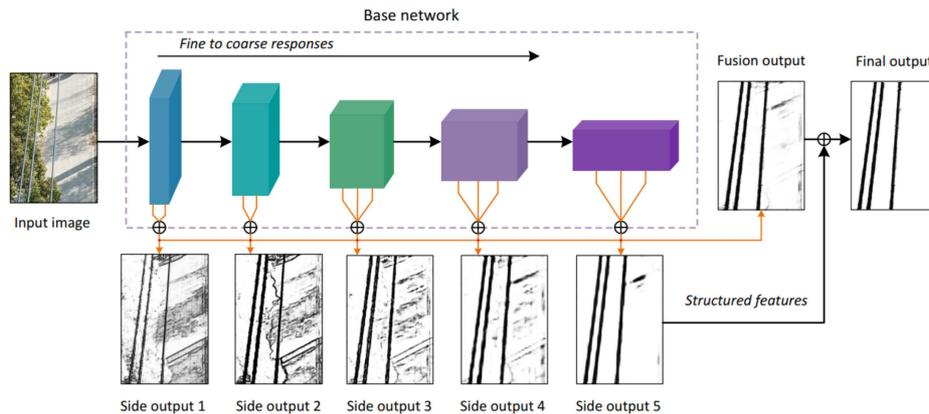


Figura 12 – Estrutura do sistema de detecção baseado em CNN. Fonte: (ZHANG et al., 2019)

para detecção de linhas de transmissão nas imagens. (ZHANG et al., 2018) empregou uma CNN para classificação de imagens que contenham ou não linhas de transmissão. (ZHANG et al., 2019) modelou uma CNN para obtenção de respostas hierárquicas de cada camada permitindo a extração de informações estruturadas, tais como: comprimento largura e orientação das linhas conforme mostrado na Figura 13. Em sua pesquisa, (LI et al., 2018) abordou o uso de uma CNN para classificar pequenas regiões da imagem que contenham linhas de transmissão e posteriormente é realizada a correlação entre regiões adjacentes permitindo a detecção robusta das linhas.

2.3 PRÉ-PROCESSAMENTO DA IMAGEM

Algumas técnicas podem ser utilizadas antes da etapa de detecção das linhas no sentido de minimizar ruídos, aprimorar as linhas e segmentar os contornos da figura. Este conjunto de operações é conhecido como processamento da imagem. Nesta seção é apresentada algumas técnicas comumente empregadas para tal finalidade.

2.3.1 Detector de Bordas *Canny*

O detector de bordas Canny é um filtro que utiliza a primeira derivada da Função Gaussiana como um operador para distinção de *pixels* contidos em um contorno. Seu princípio de funcionamento será descrito a seguir, de acordo com (CHITYALA; PUDIPEDDI, 2020).

- Inicialmente, a imagem $f(i, j)$ (A coordenada (i, j) representa a posição dos *pixels*) é suavizada através de um filtro Gaussiano do tipo passa baixa. Este processo é

realizado pela convolução da imagem original por um Kernel Gaussiano conforme a equação 2.2. Neste exemplo, um filtro de ordem 3 foi empregado.

$$G_f(i, j) = f(i, j) * \frac{1}{16} * \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (2.2)$$

- Cada *pixel* de uma borda possui uma magnitude máxima de gradiente na direção do gradiente. Desta forma, o gradiente é calculado para cada pixel através da equação:

$$G(i, j) = \sqrt{G_x(i, j)^2 + G_y(i, j)^2} \quad (2.3)$$

Na qual G_x e G_y representam os gradientes em cada eixo. A direção do gradiente é calculado através da equação :

$$\theta = \tan^{-1}\left(\frac{G_y(i, j)}{G_x(i, j)}\right) \quad (2.4)$$

- A magnitude do gradiente da imagem nos pontos de borda é máxima. Estes pontos são chamados de *pixels* de cume. Para identificação dos pontos de borda, os cumes (maiores valores de magnitude) são mantidos enquanto os outros são considerados como nulos. Esta etapa é conhecida como Supressão não máxima.
- Dois valores de *threshold* são utilizados para classificar os pixels em fortes e fracos, em um processo de histerese. Os *pixels* de cume com valores maiores que o limite superior são tratados como *pixels* de borda fortes, enquanto os *pixels* de cume com valores menores que o limite inferior são chamados de *pixels* de bordas fracos.
- Caso um *pixel* de borda fraco seja adjacente a um dos 8 *pixels* vizinhos estes são conectados. Caso contrário, os *pixels* são descartados.

Embora seja uma técnica eficiente, uma das limitações do Filtro de Canny é a determinação dos limiares máximos e mínimos para classificação dos *pixels* uma vez que estes variam de acordo com as características da imagem como o ruído e a iluminação. Desta forma, algumas pesquisas buscam métodos para obtenção de valores de maneira automática e otimizada. (OTHMAN; ABDULLAH, 2017) propôs um método para obtenção de valores ótimos através de amostragens globais e locais dentro de uma imagem por meio da divisão da mesma em vários blocos aplicando-se múltiplos níveis de resolução. (LIN; SU, 2016) aplicou o algoritmo de Otsu aliado a um método baseado no código binário de *Gray* para otimização do processo de escolha dos valores de histerese do Filtro de Canny.

2.3.2 Redes Neurais Acopladas a Pulsos (PCNN)

A rede neural acoplada a pulsos (do inglês, *Pulse Coupled Neural Network*) é um modelo baseado no funcionamento do córtex de pequenos mamíferos. Quando estimulada por imagens a PCNN exibe como saída uma série de pulsos binários sendo essa, portanto, uma ferramenta que pode ser utilizada no processamento de imagens. O tratamento de imagens através de uma PCNN baseia-se em uma série de neurônios pulsantes que podem receber estímulos dos vizinhos. Cada neurônio representa uma informação extraída de um pixel.

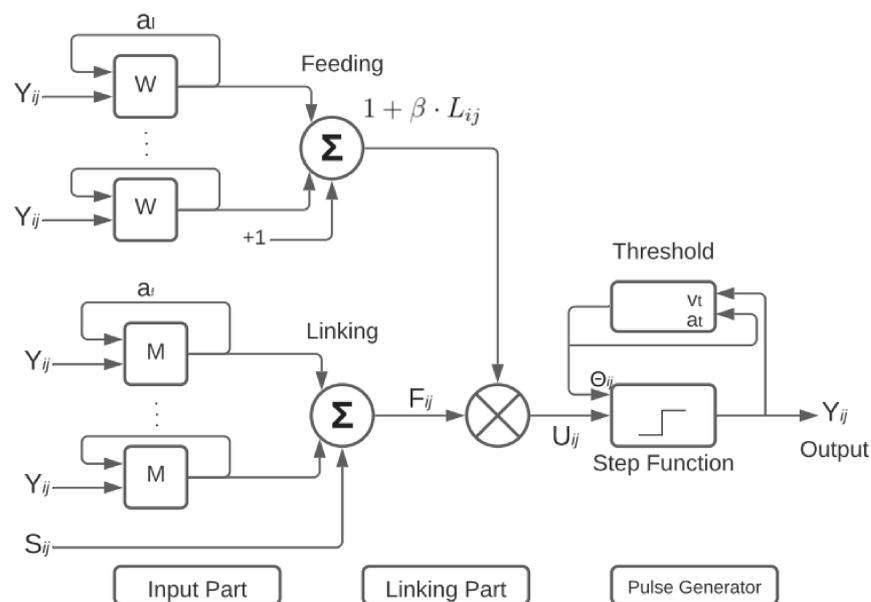


Figura 13 – Estrutura de um neurônio de uma PCNN. Fonte: (FORGÁČ; MOKRIŠ, 2005)

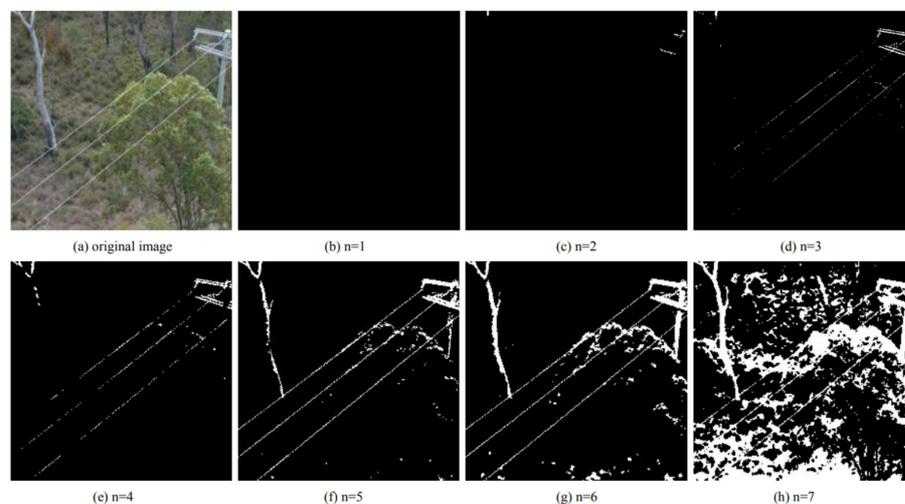


Figura 14 – Saída de uma PCNN para diferentes iterações. Fonte: (LI et al., 2010)

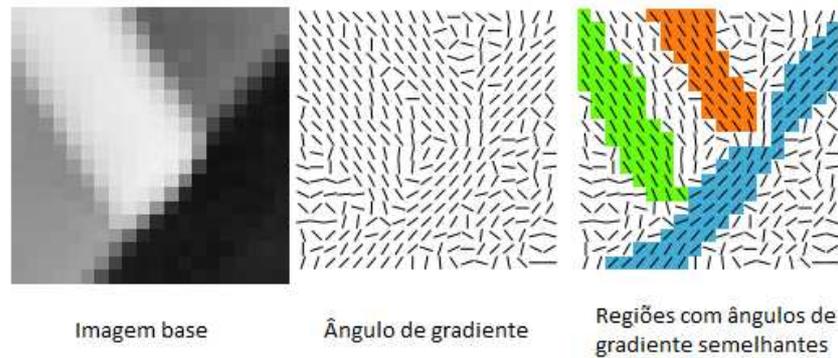


Figura 15 – Agrupamento de *pixels* em regiões com ângulo de gradiente semelhantes. Fonte: (GIOI et al., 2012)

A Figura 13 exhibe a representação de um neurônio, enquanto a Figura 14 apresenta a saída de uma PCNN em uma imagem contendo linhas de transmissão para várias iterações. Vale salientar que uma PCNN não é uma Rede Neural tradicional uma vez que não requer uma etapa de treinamento.

Alguns trabalhos na literatura propuseram melhorias para a segmentação de imagens através da PCNN. (WANG; CHEN; WANG, 2019) apresentou a junção de uma PCNN com um algoritmo de Otimização por enxame de partículas (PSO) de forma a aperfeiçoar a análise de imagens infra-vermelho contendo juntas termorretrácteis de alta tensão. Uma abordagem similar foi proposta por (BAI et al., 2017) para segmentação de elementos isolantes e posterior identificação de diferentes níveis de tensão em linhas de transmissão. Por fim, (JIANG et al., 2020) empregou uma PCNN com uma Rede Neural Convolutiva para detecção de falhas em buchas de transformadores.

2.3.3 Detector de Segmento de Linha (LSD)

O Detector de Segmentos de Linhas (do inglês, *Line Segment Detector*) é uma técnica de segmentação de linhas proposta por (GIOI et al., 2012) que dispensa a necessidade de ajuste de parâmetros. O funcionamento desta técnica baseia-se na detecção de contornos localmente lineares nas imagens. Inicialmente a imagem é transformada em escala de cinza para redução de ruídos e em seguida o ângulo do gradiente de cada *pixel* é calculado. Com isso, é possível agrupar regiões retangulares de *pixels* com ângulos de gradientes próximos dado uma certa tolerância conforme mostrado na Figura 15, e estas regiões são candidatas a segmentos de linhas. Por fim estas regiões são sujeitas a um processo de validação que reduz a detecção de falsos positivos.

Esta abordagem foi utilizada para detecção de linhas de transmissão em junção com redes neurais convolucionais no trabalho de (LUO; YU; YANG, 2021). (LUO et al., 2014), o qual propõe um método de detecção baseado na segmentação da imagem

através da LSD, e posteriormente, os segmentos são agrupados através da Transformada de Hough. Já (ZHAO et al., 2019), empregou o detector LSD como uma etapa inicial na segmentação da imagem e então utilizou o Modelo de campo aleatório de Markov (do inglês, *Markov random field model*) (MRF) para agrupar os segmentos correspondentes as linhas de transmissão.

2.3.4 EDLines

(AKINLAR; TOPAL, 2011) propôs o método EDLines para segmentação de linhas. O algoritmo principal consiste em quatro etapas: Primeiramente é realizada a convolução da imagem por um filtro gaussiano para redução de ruídos e suavização dos contornos. Em seguida, a magnitude do gradiente e direção de cada *pixel* são computadas. Desta forma, o conjunto de *pixels* com maiores valores da magnitude do gradiente são considerados âncoras ou seja: possuem alta probabilidade de pertencerem a um contorno. Por fim, esses *pixels* são conectados entre si. Esta técnica foi empregada para detecção de linhas de transmissão nos trabalhos de (ZHANG et al., 2018), (YETGIN; GEREK, 2017) e (SANTOS et al., 2017).

2.4 CONTROLADORES

Uma das etapas do presente trabalho é empregar as informações extraídas das imagens através das técnicas de segmentação e detecção das linhas a um controlador de forma a manter o VANT em uma trajetória definida, minimizando-se os erros que estão relacionados à referência escolhida. Desta forma, esta sessão trará uma breve revisão acerca das técnicas de controle usualmente empregadas em VANTs para o tratamento do problema de seguimento de trajetórias.

2.4.1 Controle Preditivo Baseado em Modelo

O controle preditivo baseado em modelo (MPC) é uma técnica de controle baseada na utilização do modelo de um determinado processo para o cálculo de um sinal de controle ótimo através da minimização de uma função objetivo sendo, portanto, considerado um Problema de Controle Ótimo (do inglês, *Optimal Control Problem*). Seu princípio de funcionamento segue os seguintes passos :

- Dado os estados do sistema em um determinado tempo t (Ou para um modelo discreto, k) e o modelo dinâmico do processo, o controlador realiza a predição dos estados futuros através de um horizonte de predição T_p .
- Em seguida é realizado o cálculo das ações de controle em um horizonte de controle ($T_c, T_c \leq T_p$) através da minimização de uma função objetivo que está sujeita a restrições nos estados e nas saídas do sistema.

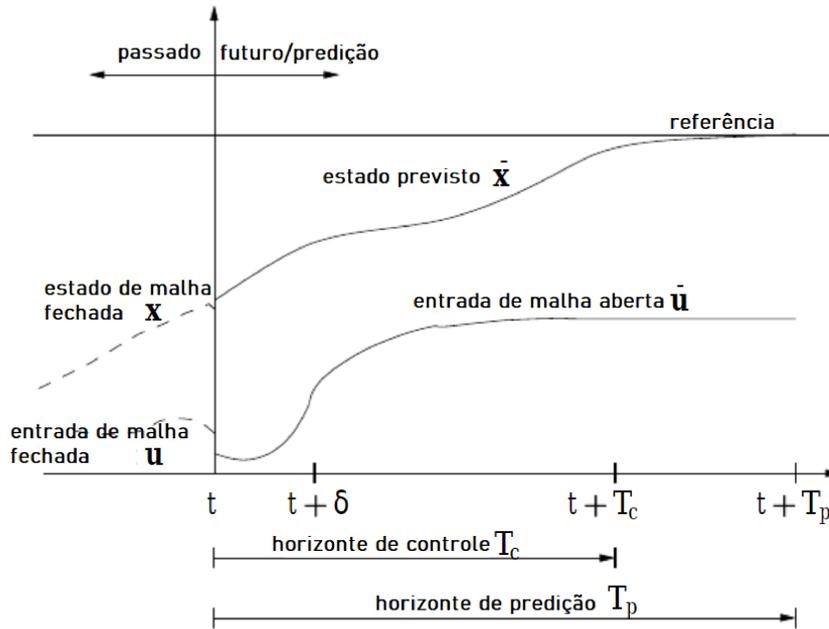


Figura 16 – Princípio de um controle MPC. Fonte: (FINDEISEN; ALLGÖWER, 2002)

- O primeiro sinal de controle obtido ($u(k)$) é aplicado ao processo durante todo período de amostragem (σ) e o horizonte de tempo é deslocado ($u(k+1)$).

As etapas supracitadas podem ser vistas na Figura 16. Uma variante do controle MPC é o Controle Preditivo Baseado em Modelo Não-linear (NMPC). Sua distinção está na modelagem do sistema através de equações diferenciais não-lineares e/ou funções de custo não-quadráticas e restrições não-lineares. O presente trabalho assume o controle NMPC com um modelo de sistema não linear, função de custo quadrática e restrições lineares. Mais detalhes serão apresentados no capítulo 3. O controle NMPC é descrito de forma generalizada pelos artigos de (ALLGOWER et al., 2004), (RIBEIRO; CONCEIÇÃO, 2019) através da seguinte formulação :

Considerando um sistema contínuo no tempo descrito pela seguinte equação :

$$\dot{x} = f(x(t), u(t)), \quad x(0) = x_0 \quad (2.5)$$

Sujeito a restrições de entrada e de estado do tipo :

$$u(t) \in U, \forall t \geq 0, \quad (2.6)$$

$$x(t) \in X, \forall t \geq 0, \quad (2.7)$$

Em que, $u \in R^m$ e $x \in R^n$ indicam os vetores de entrada e estados respectivamente. U e X são conjuntos de valores admissíveis que são dados, geralmente, por restrições do tipo :

$$U := \{u \in R^m \mid u_{min} \leq u \leq u_{max}\} \quad (2.8)$$

$$R := \{r \in R^n \mid x_{min} \leq x \leq x_{max}\} \quad (2.9)$$

Em que $u_{min}, x_{min}, u_{max}, x_{max}$ são valores constantes.

Em seguida, as ações de controle que serão enviadas ao sistema são calculadas através do problema otimização de horizonte finito :

$$\min_{\bar{u}(\cdot)} J(x(t), \bar{u}(\cdot)) \quad (2.10)$$

Sujeito à:

$$\dot{\bar{x}}(\tau) = f(\bar{x}(\tau), \bar{u}(\tau)), \bar{x}(t) = x(t), \quad (2.11)$$

$$\bar{u}(\tau) \in U, \forall \tau \in [t, t + T_c], \quad (2.12)$$

$$\bar{u}(\tau) = \bar{u}(t + T_c), \forall \tau \in [t + T_c, t + T_p], \quad (2.13)$$

$$\bar{x}(\tau) \in X, \forall \tau \in [t, t + T_c], \quad (2.14)$$

Com a função objetivo do tipo :

$$J(x(t), \bar{u}(\cdot)) := \int_t^{t+T_p} F(\bar{x}(\tau), \bar{u}(\tau)) d\tau \quad (2.15)$$

Os termos T_p e T_c indicam os horizontes de predição e controle respectivamente, com $T_p \leq T_c$. Os termos com barras (\bar{x} e \bar{u}) indicam variáveis internas do controlador que são diferentes das reais variáveis do sistema uma vez que são calculadas com relação a um horizonte finito. A função de objetivo J pode ser definida através da função de custo F que geralmente é apresentada pela função quadrática :

$$F(x, u) = (x - x_s)^T Q (x - x_s) + (u - u_s)^T R (u - u_s) \quad (2.16)$$

Em que x_s e u_s indicam as referências desejadas para o sistema. Seus valores são ponderados pelas matrizes semi-definidas positivas Q_{1, n_x} e R_{1, n_u} , em que n_x e n_u são os números de estados e números de variáveis de saída, respectivamente.

Em teoria, a estratégia ideal é escolher valores infinitos para o horizonte de predição e controle, uma vez que isso minimiza o custo da função objetivo (ALLGOWER et al.,

2004). Entretanto, a adoção de horizontes infinitos acarretam em um maior esforço computacional para resolução do problema de otimização e, desta forma, são adotados, preferencialmente, valores pequenos para estes horizontes. Uma das consequências desta estratégia é que os valores previstos para os estados se afastam do atual estado do processo o que pode acarretar na instabilidade do sistema. Uma alternativa usual para lidar com esse problema é a adoção de uma restrição terminal do tipo :

$$\bar{x}(t + T_p) \in \Omega \quad (2.17)$$

Sendo Ω a região de valores admissíveis para o estágio final $t + T_p$. Além da adição de um termo $E(\bar{x}(t + T_p))$ que penaliza o estágio final. Com isso a função objetivo da Equação 2.15 adota a seguinte forma :

$$J(x(t), \bar{u}(\cdot)) := \int_t^{t+T_p} F(\bar{x}(\tau), \bar{u}(\tau))d\tau + E(\bar{x}(t + T_p)) \quad (2.18)$$

Diversos estudos na literatura adotaram estratégias baseadas em controladores NMPC para o planejamento de trajetórias locais utilizando-se de VANTs. O trabalho de (NASCIMENTO et al., 2019) apresenta o uso do controle NMPC para navegação em ambientes desconhecidos, considerando a distância para obstáculos estáticos que servem de base para a determinação das restrições a serem impostas ao controlador. (LINDQVIST et al., 2020) propõe um esquema baseado em NMPC capaz de planejar a trajetória de um VANT em tempo real, que permite a predição da trajetória de possíveis obstáculos sendo, portanto, capaz de evitar colisões contra alvos móveis e estáticos. Já o artigo de (MANSOURI et al., 2018) apresenta uma ferramenta para inspeção aérea de estruturas tridimensionais através de um conjunto de VANTs e, dentre as técnicas utilizadas no trabalho, o planejamento da trajetória dos drones é realizado por meio de um controlador NMPC.

2.4.2 Controle Servo Visual Baseado na Imagem (IBVS)

O Controle Servo Visual Baseado na Imagem (do inglês, *Image-based Visual Servoing*) é uma técnica que baseia-se em informações extraídas no plano de imagens, permitindo o controle de um robô de acordo com a posição de um determinado alvo na imagem, podendo este ser uma linha, uma *tag* ou um objeto qualquer. Preferencialmente, o centro da imagem é adotado como a referência da trajetória (BISTA; GIORDANO; CHAUMETTE, 2016) e, desta maneira, um erro de referência pode ser definido como a diferença da posição do alvo com o ponto central da imagem. Este erro pode ser inserido a um controlador que determinará as ações de controle a serem adotadas.

Uma das alternativas para seguimento de trajetórias com VANTs baseando-se em arquiteturas IBVS é o controle MPC ou sua variante não linear NMPC. Nesta linha



Figura 17 – VANT sobrevoando objetos detectados por uma câmera. Fonte: (FALANGA et al., 2018)

de pesquisa (FALANGA et al., 2018) propôs uma técnica que alia o processamento de imagens com o controle MPC de forma com que o VANT sobrevoe uma região mantendo sua orientação apontada ao centróide dos objetos detectados por uma câmera, conforme mostrado na Figura 17. Uma abordagem semelhante foi abordada por (ROQUE et al., 2020). Já (LOPEZ-FRANCO et al., 2017) empregou uma topologia envolvendo um controlador PID (Proporcional Integral e derivativo) com redes neurais de forma a controlar a posição do VANT enquanto este acompanha uma imagem contendo um Código QR. Por fim, um modelo IBVS com um Controlador *Backstepping* foi empregado por (ZHENG et al., 2016).

2.4.3 Controle Proporcional Integral e Derivativo

O Controle Proporcional Integral e Derivativo (PID) é um tipo de controle clássico com diversas aplicações no âmbito industrial, devido à características como a simplicidade de projeto, facilidade de implementação para diversos modelos e baixo custo financeiro e computacional (BORASE et al., 2021).

Seu princípio de funcionamento se baseia na retroalimentação das saídas da planta com uma posterior comparação com os valores desejados para os estados o que resulta em um erro. Este erro é transmitido a três blocos, um proporcional, um derivativo e um integrativo que, em conjunto, determinam uma ação de controle a ser enviada a planta. Um esquema clássico de controle PID é mostrado na Figura 18.

A saída do controlador é dada pela Equação :

$$U_{PID}(t) = K_c e(t) + \frac{K_c}{\tau_I} \int e(t) dt + K_c \tau_D \frac{de}{dt} \quad (2.19)$$

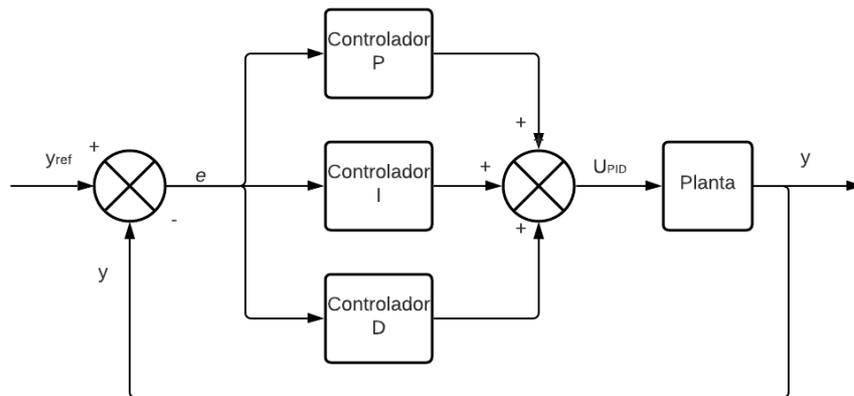


Figura 18 – Estrutura de um controlador PID clássico. Fonte: (KUMAR; NAKRA; MITTAL, 2011)

Em que K_c é a constante Proporcional, τ_I é constante de tempo integral, τ_D é a constante de tempo derivativo e $U_{PID}(t)$ é a saída do controlador PID.

Embora o controle PID seja simples e eficaz para muitos processos, sua implementação para o controle de VANTs apresenta algumas desvantagens por se tratar de um sistema não-linear, multivariável, sujeito a distúrbios externos e restrições nos estados. Desta forma, algumas soluções propõem o emprego de versões adaptadas desta técnica em junção com outros controladores para resolução de problemas de planejamento de trajetórias envolvendo veículos multirotores. (NAJM; IBRAHEEM, 2019) propôs uma arquitetura composta por seis blocos de controladores PID não lineares, um bloco para cada grau de liberdade do VANT. Os parâmetros de cada controlador é sintonizado através do Algoritmo Genético (GA). Em seu trabalho, (HAMIDI et al., 2019) empregou um controlador PID auto-sintonizado por controladores baseados em redes neurais e pela Otimização por Enxame de Partículas (PSO) para o seguimento de trajetórias de um VANT. Por fim (CHENG; YANG, 2017) atacou o mesmo problema utilizando um controlador NMPC aliado a um controle de altitude baseado em um controlador PID.

2.4.4 Outras técnicas de controle

Além das técnicas supracitadas, a literatura apresenta diversas outras metodologias para o controle posicional de um VANT enquanto este segue uma determinada trajetória. Topologias baseadas no Controle por Modos Deslizantes (do inglês, *Sliding Mode Control*) (SMC) foram empregadas em conjunto com um planejador de trajetórias nos trabalhos de (MU; PEI; SHI, 2017), (MOFID; MOBAYEN, 2018), (WANG et al., 2018) e (HUANG et al., 2019). A técnica de controle baseada na Teoria de Lyapunov foi adotada em (RAJ; RAGHUWAIYA; VANUALAILAI, 2020) e (LUGO-CÁRDENAS; SALAZAR; LOZANO, 2017). Já o Controle por Linearização de Feedback (do inglês, Feedback Linea-

rization Control) foi escolhido pelos trabalhos de (ABBASI; GHAYOUR; DANESH, 2017) e (MEHNDIRATTA et al., 2019). O trabalho de (RUBÍ; PÉREZ; MORCEGO, 2020) apresentou uma revisão de técnicas de controle aplicadas ao problema de seguimento de trajetórias com VANTs, apresentando vantagens e desvantagens de cada técnica. A Tabela 2 sumariza a comparação realizada. Para a coluna de estrutura, IGC indica Controle Integrado de movimentação (do inglês, Integrated guidance and Control) e SGC indica Controle Separado de movimentação (do inglês, Separated Guidance and Control) (SGC). A coluna CTF indica a presença de Controle de Tolerância à falhas. O controle MPC foi escolhido para esta dissertação devido a características como: modelo dinâmico não linear dos VANTs e capacidade de imposição de restrições na saída e nos estados do sistema. Além disso o controlador se mostrou satisfatório para o seguimento de linhas, conforme os trabalhos de (MARIA et al., 2020) e (RIBEIRO; CONCEIÇÃO, 2019).

Tabela 2 – Comparação dos métodos de detecção de linhas

	Estrutura	Resultados	VANT	Vento	CTF	Adaptativo
<i>Model Predictive Control</i>	SGC	Experimental	Sim	Sim	Não	Sim
<i>Lyapunov-based Control</i>	SGC e IGC	Experimental	Sim	Sim	Não	Sim
<i>Sliding Mode Control</i>	SGC e IGC	Experimental	Não	Sim	Não	Não
<i>Feedback Linearization Control</i>	SGC e IGC	Experimental	Sim	Não	Não	Não

2.5 Ajuste de Curvas

As técnicas de detecção de retas mostradas na Seção 2.2 são capazes de destacar linhas de transmissão em imagens, porém em muito dos casos, não possuem a capacidade de distinção destas linhas com elementos como muros de concreto e marcações no asfalto. Assim, considerando a tarefa de seguimento de linhas de transmissão como um problema de seguimento de caminhos visuais é necessário o tratamento informações visuais obtidas pelas etapas de processamento e segmentação das linhas, de forma a determinar o percurso a ser seguido mesmo na presença de retas que não correspondam ao caminho desejado. Este processo é realizado ajustando-se o conjunto de dados de entrada (*pixels* correspondentes a retas) em uma única curva que corresponde a trajetória a ser adotada pelo VANT. Esta sessão traz algumas metodologias empregadas para o ajuste de curvas.

2.5.1 Método dos Mínimos Quadrados

O Método dos Mínimos Quadrados (do inglês, *Ordinary Least Squares*)(OLS) é uma técnica de ajuste de curvas que baseia-se na minimização da soma dos quadrados das diferenças entre um vetor de amostras e o valor esperado, sendo este, portanto, um problema de otimização. A formulação do método é dada a seguir, conforme apresentado por (HANSEN; PEREYRA; SCHERER, 2013) :

Um problema de mínimos quadrados é, normalmente, descrito pela equação :

$$\min \| b - Ax \|_2 \quad (2.20)$$

Em que $A \in \mathbb{R}_{m \times n}$ é a matriz com as amostras do modelo, x é o vetor com os parâmetros a serem determinados e b é o vetor de observações.

Desta forma, o vetor residual pode ser definido como :

$$r = b - Ax \quad (2.21)$$

A solução do problema é denotada por x^* que difere-se de x uma vez que x^* pode apresentar múltiplas soluções. Para que x^* seja um candidato para a solução do problema de minimização da função $\rho(x) = \| b - Ax \|_2^2$, a seguinte condição deve ser satisfeita :

$$\nabla \rho(x) = \frac{\partial \rho(x)}{\partial x_k} = 0, k = 1, \dots, n \quad (2.22)$$

Com isso :

$$\nabla \rho(x) = -2A^T r = -2A^T (b - Ax) \quad (2.23)$$

Juntando 2.22 com 2.23, tem-se a seguinte condição :

$$A^T (b - Ax) = 0 \quad (2.24)$$

Manipulando-se a equação 2.24 chega-se, por fim, na solução de x^* :

$$x^* = (A^T A)^{-1} A^T b \quad (2.25)$$

2.5.2 RANSAC

O método RANSAC (Random Sample Consensus) é um algoritmo de ajuste de curvas robusto proposto por (FISCHLER; BOLLES, 1981). A robustez da técnica se dá pela capacidade do mesmo de rejeitar a influência de *outliers* (Erros grosseiros que não fazem parte do modelo) diferentemente do Método dos Mínimos Quadrados que atribui o mesmo peso para todos os dados da amostra. Seu princípio de funcionamento baseia-se na determinação dos parâmetros do modelo através de uma amostragem mínima dos dados. É um algoritmo iterativo no sentido de que os parâmetros são refinados a cada iteração de acordo com a relação entre *inliers* (Dados pertencentes ao modelo) e *outliers* (Dados que podem ser interpretados como ruídos). O conceito básico do algoritmo é apresentado a seguir (DERPANIS, 2010):

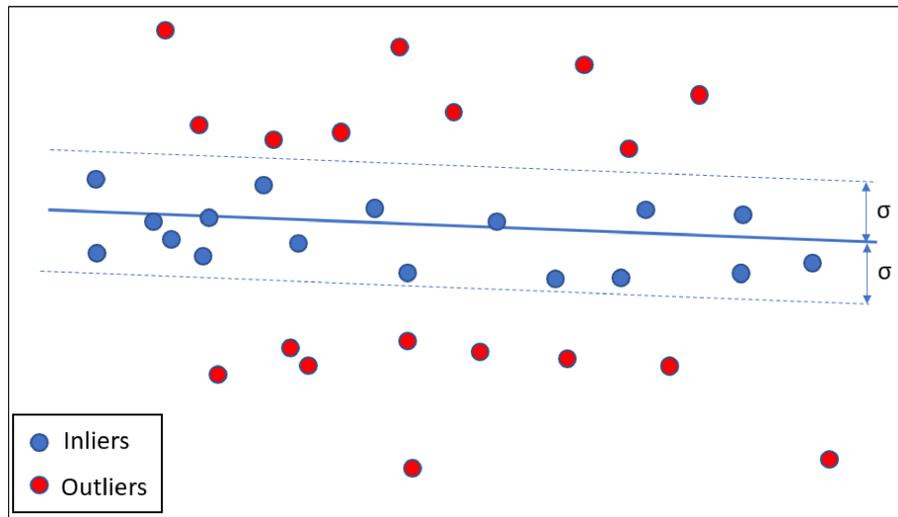


Figura 19 – Representação da etapa de classificação de *inliers/outliers*. Fonte: do autor.

1. Seleciona-se um conjunto mínimo de amostras aleatórias para determinação dos parâmetros do modelo (Exemplo: 2 pontos para uma modelo linear e 3 pontos para uma modelo de segunda ordem).
2. Em seguida, calcula-se os parâmetros do modelo com base nos pontos escolhidos.
3. Os demais dados são classificados em *inlier* caso a distância do ponto ao modelo seja menor que um *threshold* (σ) ou *outlier* caso a distância ultrapasse o *threshold*. Esta etapa é mostrada na Figura 19.
4. Caso a relação entre o número de *inliers* e a quantidade total de amostras ultrapassar um limiar definido, os parâmetros do modelo são re-estimados somente utilizando-se os *inliers* e o algoritmo se encerra.
5. Caso contrário, repete-se os passos 1 ao 4 (Com um máximo de N iterações).

A quantidade N de iterações é escolhida de forma com que exista a probabilidade p de que pelo menos um conjunto de amostras não possua um *outlier*. Seu valor é determinado de acordo com a seguinte equação :

$$N = \frac{\log(1 - p)}{\log(1 - (1 - v)^m)} \quad (2.26)$$

Em que u é probabilidade de que uma amostra seja um *inlier*, $v = 1 - u$ é a probabilidade de que uma amostra seja um *outlier* e m é número mínimo de pontos requeridos para estimação do modelo.

2.5.3 Regressor de Theil-Sen

O Regressor de Theil-Sen é um método de ajuste de curvas robusto capaz de lidar com dados ruidosos. Seu princípio de funcionamento está na combinação determinação dos parâmetros do modelo através da mediana dos coeficientes de uma sub-população de todas as combinações de pontos de um determinado conjunto. O método pode ser resumido da seguinte forma (GRANATO; LINE, 2006) :

A regressão de um modelo linear pode ser descrita pela seguinte equação :

$$Y_i = mX_i + b + e_i, i = 1, \dots, n \quad (2.27)$$

Em que e_i é o erro residual, m é o coeficiente angular estimado da reta, b é o coeficiente linear estimado da reta e n é número de dados na amostra.

O coeficiente angular da reta é calculado através da mediana de todos os pares de pontos da amostra que podem ser determinados individualmente pela equação :

$$m_{i,j} = \frac{Y_j - Y_i}{X_j - X_i}, i = 1, \dots, n - 1 \text{ e } j = 2, \dots, n \quad (2.28)$$

O coeficiente linear é determinado através da equação :

$$b = Y_{med} - mX_{med} \quad (2.29)$$

Em que Y_{med} é a mediana dos valores de Y da amostra e X_{med} é a mediana dos valores de X da amostra.

Por fim, o erro residual para cada dado pode ser determinado por :

$$e(i) = Y_i - (mX_i + b) \quad (2.30)$$

2.5.4 Regressor de Huber

O Regressor de Huber é uma técnica de ajuste de curvas que, assim como o Método dos Mínimos Quadrados, determina os parâmetros do modelo através de um problema de otimização. Sua principal diferença está na escolha de uma função que penaliza os *outliers* de forma linear e os *inliers* de forma quadrática. Desta maneira, o efeito dos *outliers* é reduzido, diferentemente do RANSAC e do Regressor Theil-Sen que os ignoram.

A técnica resume-se na minimização da seguinte equação (OWEN, 2007) :

$$\min \sum_{i=1}^n \phi(y_i - x_i^T \beta), \beta \in \mathbb{R}^n \quad (2.31)$$

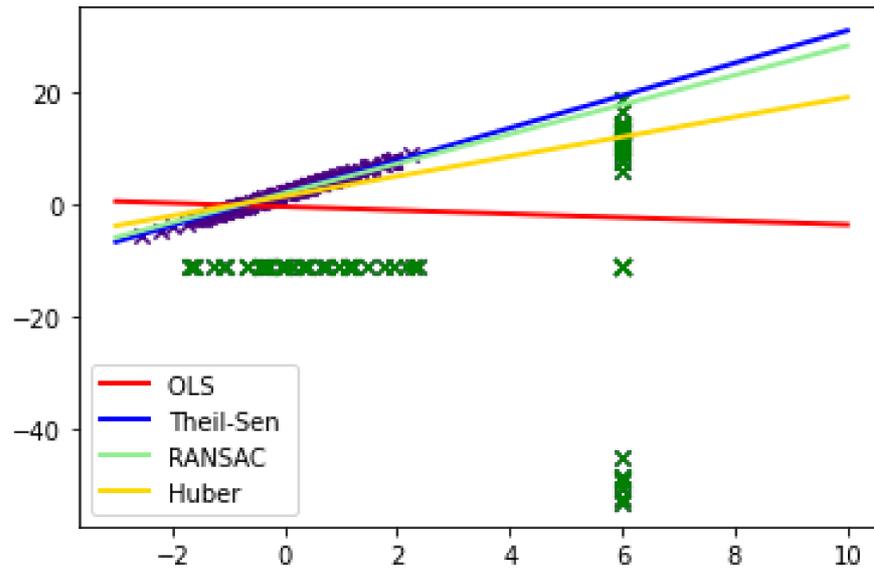


Figura 20 – Comparação dos métodos de Ajuste de Curvas. Os pontos em roxo indicam as amostras que fazem parte do modelo enquanto os pontos em verde são amostras ruidosas. Fonte: do autor.

Em que ϕ é a Função de Perda de Huber que assume a seguinte forma :

$$\phi(u) = \begin{cases} u^2 & \text{se } |u| \leq \varepsilon \\ 2\varepsilon u - \varepsilon^2 & \text{se } |u| > \varepsilon \end{cases} \quad (2.32)$$

Em que ε é um valor de limiar que classifica os pontos em *inliers* e *outliers*.

A Figura 20 apresenta um comparativo entre os quatro métodos de ajuste abordados nesta seção para um caso no qual deseja-se estimar os parâmetros de uma curva na presença de dados espúrios. Neste exemplo, os pontos em roxo indicam as amostras que fazem parte do modelo enquanto os pontos em verde são amostras ruidosas.

Pelas curvas obtidas pelos quatro métodos percebe-se que, para este exemplo, as técnicas RANSAC e Theil-Sen foram as que mais se aproximaram dos pontos que de fato fazem parte do modelo. Para o caso de Huber, como o peso para os *inliers* é maior se comparado aos *outliers*, a curva tendeu a amostras pertencentes ao modelo com um leve desvio causado pelos *outliers*. A curva obtida pelo método OLS que, conforme explicado anteriormente, trata todas as amostras com o mesmo peso sofreu um forte desvio devido a amostras distantes do modelo.

Uma análise qualitativa dos métodos aplicados ao problema de determinação da trajetória para o seguimento de caminhos visuais será abordada com mais detalhes no Capítulo 4.

2.6 Conclusões

Este capítulo teve como objetivo abordar trabalhos da literatura relacionados aos tópicos explorados na presente dissertação.

Inicialmente foram apresentados estudos acerca da utilização de VANTs para inspeção de linhas de transmissão, mais especificamente com relação a trajetória que deve ser adotada. Nesta linha de pesquisa, o planejamento da trajetória pode ser realizado de forma global com o uso de dados obtidos por GPS, de forma local com a utilização de câmeras e/ou sensores de proximidade permitindo um seguimento mais refinado, com a possibilidade de desvio de obstáculos não previstos ou abordagens mistas que permitem uma inspeção mais robusta e segura.

Em seguida, foram expostas algumas técnicas referentes à detecção de linhas genéricas, processamento de imagens e controladores utilizados em problemas de seguimento de trajetórias. O enfoque foi dado na apresentação de trabalhos que empregam estas metodologias na detecção de linhas de transmissão e o seguimento através de VANTs.

Por fim, são apresentadas algumas técnicas referentes ao ajuste de curvas. Estes métodos podem ser robustos, caso consigam rejeitar o efeito de amostras ruidosas ou não-robustos quando tratam todos os pontos com o mesmo peso. Em aplicações passíveis de erros de detecção como o presente trabalho existe a preferência por técnicas que eliminem ou mitiguem pontos que não fazem parte do modelo.

3 METODOLOGIA

Neste capítulo serão abordadas as metodologias envolvidas na resolução do problema de seguimento das linhas de transmissão através de um VANT. Inicialmente será apresentado a formulação matemática e representação gráfica do problema. Em seguida aspectos como o tratamento da imagem, detecção das linhas, cálculo da trajetória e controlador serão explorados com mais detalhes. Por fim é mostrada a integração dos sensores/atuadores com o sistema de detecção e controle que é realizada através da plataforma ROS. A Figura 21 apresenta um diagrama dos passos abordados nesta seção

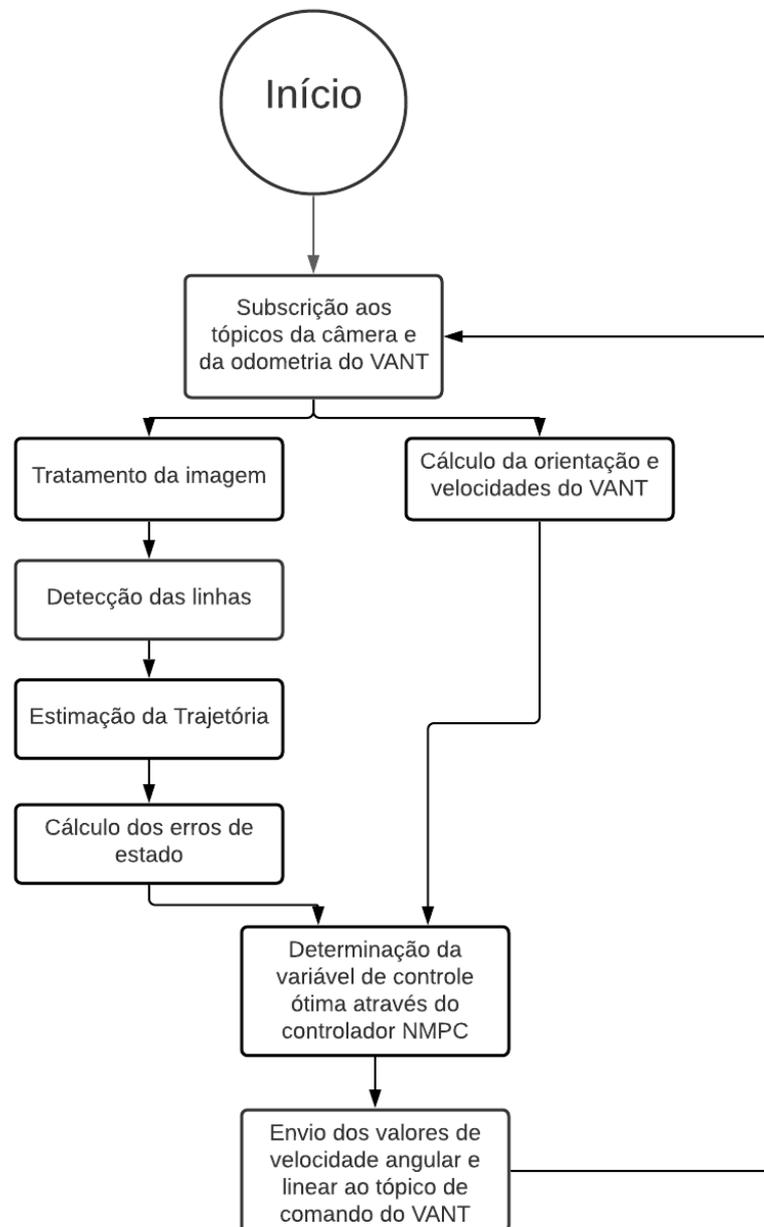


Figura 21 – Diagrama das etapas referentes a metodologia proposta. Fonte: do autor.



Figura 22 – Exemplos de referências adotadas em imagens de linhas de transmissão. Fonte: (ZHANG et al., 2019).

3.1 Representação do problema de seguimento de linhas de transmissão

Conforme explicado na Seção 2.4.2, o seguimento de trajetórias definidas por caminhos visuais pode ser sumarizado em: manter o robô posicionado com relação a um referencial extraído da imagem. Para o caso de linhas de transmissão, no qual a quantidade de linhas dispostas em uma determinado local é variável, a referência adotada será o ponto central entre as linhas na região central da imagem. Adicionalmente, pontos vizinhos são considerados de forma a determinar a orientação angular da trajetória.

A Figura 22 mostra exemplos de referências extraídas de imagens contendo linhas de transmissão. Os pontos vermelhos indicam a posição central da trajetória enquanto os pontos azuis representam pontos adicionais para o cálculo da orientação. A imagem da esquerda possui 3 linhas de transmissão visíveis e, desta forma, a referência esperada é a linha central. Para a imagem da direita, como o número de linhas é par, a trajetória adotada é equidistante das linhas com a orientação paralela as mesmas.

Com isso, dois tipos de referenciais serão adotados nesta dissertação. O VANT deve seguir as linhas de transmissão com uma distância longitudinal nula do ponto central o que significa manter as linhas no centro da imagem com a orientação paralela às mesmas. A Figura 23 apresenta as vistas superior e lateral para o problema proposto contendo as variáveis que serão abordadas a seguir. Neste exemplo, o VANT segue o referencial P_f com uma velocidade de avanço linear na direção de X_r a uma altura H das linhas. Assim pode-se determinar dois erros referenciais: um longitudinal (Z) e um angular (Φ_r).

Estes valores devem ser minimizados através do ajuste da orientação do VANT que será determinado pela saída do controlador NMPC.

Para a formulação do problema são considerados dois *frames*: R que está acoplado ao o centro de massa do VANT representado pelos eixos X_r, Y_r e Z_r , e o *frame* inercial W representado pelos eixos X_w, Y_w e Z_w . Com isso, a primeira etapa é a transformação dos *frames* referentes às equações cinemáticas de um VANT. Para tal, será considerado um modelo de VANT não-holonômico no qual a velocidade em *roll* (p) é considerada nula permitindo a movimentação do *drone* através de uma taxa de arfagem (*pitch*) e de guinada (*yaw*). O equacionamento a seguir é uma adaptação do trabalho de (ELÉTRICA; SILVA, 2017) considerando um modelo não-holonômico :

$$\begin{pmatrix} \dot{x} \\ \dot{y} \\ \dot{\varphi} \end{pmatrix} = \begin{pmatrix} \cos(\theta)\cos(\varphi) & \text{sen}(\phi)\text{sen}(\theta)\cos(\varphi) - \cos(\phi)\text{sen}(\phi) & 0 & 0 \\ \cos(\phi)\text{sen}(\varphi) & \text{sen}(\phi)\text{sen}(\theta)\cos(\varphi) + \cos(\phi)\cos(\varphi) & 0 & 0 \\ 0 & 0 & \frac{\text{sen}(\phi)}{\cos(\theta)} & \frac{\cos(\phi)}{\cos(\theta)} \end{pmatrix} \begin{pmatrix} u \\ v \\ q \\ r \end{pmatrix} \quad (3.1)$$

Em que \dot{x} é a taxa de variação da posição inercial do VANT em relação ao referencial X_w , \dot{y} é a taxa de variação da posição inercial do VANT em relação ao referencial Y_w , $\dot{\varphi}$ é a taxa de variação do ângulo de guinada (*yaw*) em relação ao referencial Z_w , θ é o ângulo de arfagem (*pitch*) em relação à W , φ é o ângulo de guinada (*yaw*) em relação à W , ϕ é o ângulo de rolagem (*roll*) em relação à W , u é a velocidade medida ao longo do eixo X_r em R , v é a velocidade medida ao longo do eixo Y_r em R , q é a taxa de arfagem (*pitch*) medida ao longo do eixo Y_r em R , r é taxa de guinada (*yaw*) medida ao longo do eixo Z_r em R .

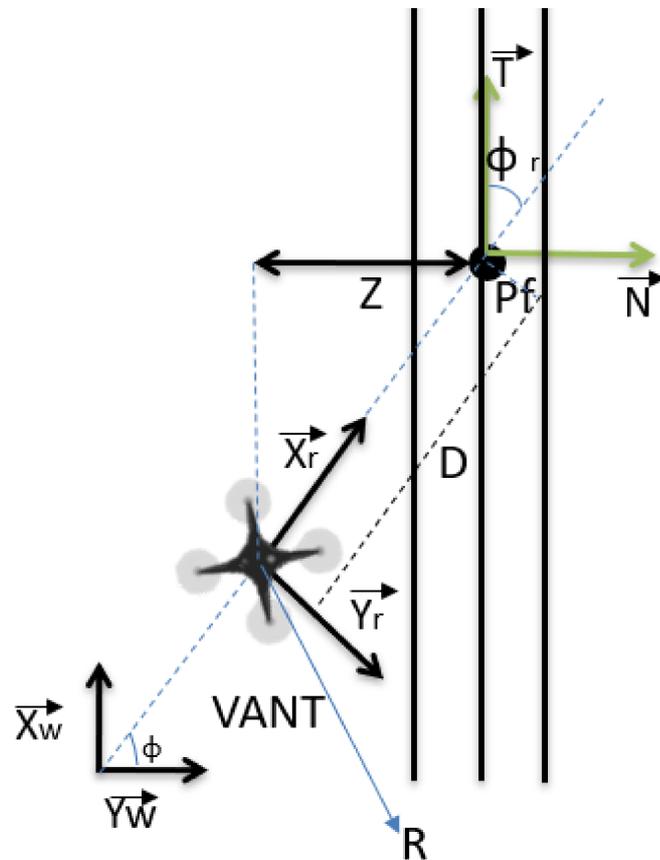
Desmembrando as matrizes da Equação 3.1, considerando $\phi = 0$, o seguinte conjunto de equações pode ser definido :

$$\dot{x} = u\cos(\theta)\cos(\varphi) - v\cos(\theta)\sin(\varphi) \quad (3.2)$$

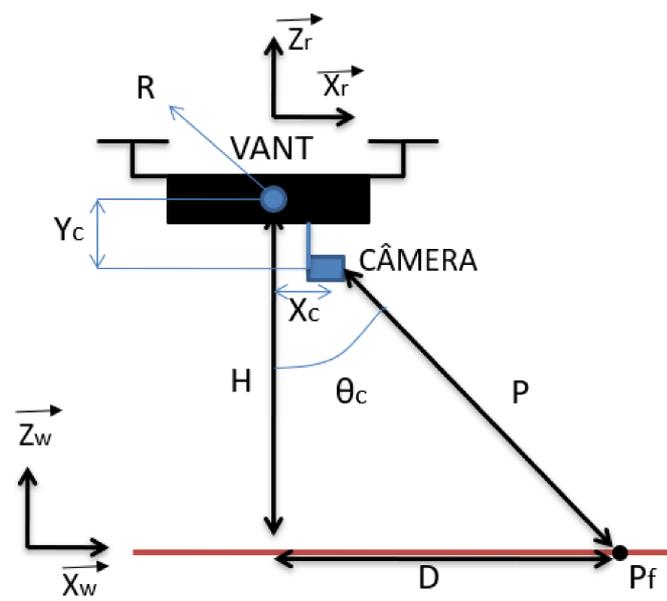
$$\dot{y} = u\sin(\theta) + v\cos(\varphi) \quad (3.3)$$

$$\dot{\varphi} = \frac{\cos(\phi)}{\cos(\theta)}r \quad (3.4)$$

Em seguida, o problema de segmento de trajetórias é considerado através do sistema de coordenadas de Serret-Frenet, conforme os trabalhos de (RIBEIRO; CONCEIÇÃO, 2019) e (WANG et al., 2018). A transformação do sistema de coordenadas do robô



(a) Vista superior.



(b) Vista lateral

Figura 23 – Vistas do problema proposto. Fonte: do autor.

relacionado ao frame R para o sistema Serret-frenet SF é mostrada na Equação 3.5. A partir desta, podem ser definidas as Equações 3.6 e 3.7.

$$\begin{pmatrix} X_r \\ Y_r \end{pmatrix} = \begin{pmatrix} \cos(\phi_r) & \sin(\phi_r) \\ -\sin(\phi_r) & \cos(\phi_r) \end{pmatrix} \begin{pmatrix} T \\ N \end{pmatrix} \quad (3.5)$$

$$\dot{Z} = \frac{\cos(\phi)}{\cos(\theta)} r D + \frac{\left(\frac{\cos(\phi)}{\cos(\theta)} r Z + u \cos(\theta) \cos(\varphi) - v \sin(\varphi) \right)}{\tan(\varphi_r)} \quad (3.6)$$

$$\dot{s} = \frac{u \cos(\theta) \cos(\varphi) - v \cos(\theta) \sin(\varphi) + \frac{\cos(\phi)}{\cos(\theta)} r Z}{\cos(\varphi_r)} \quad (3.7)$$

Em que Z é o erro longitudinal do VANT com relação ao ponto P_f , φ_r é o erro angular entre o eixo longitudinal do VANT (X_r) e a tangente (T) da trajetória no ponto P_f e D é o horizonte para avaliação das variáveis de erro do problema.

De acordo com a Figura 23 a seguinte relação pode ser obtida, considerando φ_c como sendo a direção da curvatura de uma trajetória genérica. Para o caso do seguimento de linhas de transmissão cuja trajetória é retilínea considera-se $\varphi_c = 0$. Desta forma:

$$\varphi_r = \varphi - \varphi_c \quad (3.8)$$

Derivando a Equação 3.8 tem-se que:

$$\dot{\varphi}_r = \dot{\varphi} - \dot{s} C \quad (3.9)$$

Na qual s é a abscissa curvilínea do caminho a ser seguido e C é a curvatura da trajetória que pode ser calculada através da seguinte equação:

$$C = \frac{\left| \left(\frac{\partial^2 x}{\partial t^2} \frac{dy}{dt} \right) - \left(\frac{dx}{dt} \frac{\partial^2 y}{\partial t^2} \right) \right|}{\left(\frac{dx}{dt} \frac{dx}{dt} + \frac{dy}{dt} \frac{dy}{dt} \right)^{\frac{3}{2}}} \quad (3.10)$$

Para resolução do problema de seguimento de trajetórias como um problema de otimização através do controlador NMPC as seguintes variáveis são definidas:

$$\dot{x}_e = \begin{bmatrix} \dot{Z} \\ \dot{\varphi}_r \end{bmatrix} = \begin{bmatrix} \dot{Z} \\ u_{opt} \end{bmatrix} \quad (3.11)$$

Em que \dot{x}_e é o vetor de erros dos estados, u_{opt} ou $\dot{\varphi}_r$ é a variável de controle ótima. \dot{Z} é dado pela Equação 3.6. A variável de esforço de controle r que será aplicado pelo

VANT de forma a minimizar o vetor de erros de estado pode ser calculada através da junção das Equações 3.9 e 3.7, de forma que:

$$r = \frac{u_{opt}(\cos(\varphi_r)) + C(u \cos(\theta)\cos(\varphi) - v \operatorname{sen}(\varphi))}{(\cos(\varphi_r) - C Z) \frac{1}{\cos(\theta)}} \quad (3.12)$$

Considerando uma trajetória retilínea e, portanto, $C = 0$, a seguinte simplificação pode ser adotada :

$$r = u_{opt}\cos(\theta) \quad (3.13)$$

3.2 Tratamento da Imagem

A detecção de objetos ou formas geométricas é uma tarefa trivial para os humanos diferentemente de algoritmos de visão computacional nos quais fatores como a qualidade da imagem, presença de ruídos e iluminação podem afetar a detectabilidade desses elementos. Desta forma, com o conhecimento prévio do que se quer extrair de uma determinada imagem, algumas técnicas podem ser empregadas permitindo a intensificação dos itens de interesse reduzindo o efeito de elementos espúrios.

Uma câmera digital permite a captação de um fluxo de imagens denominados de *frames*. Estes *frames* são tratados computacionalmente como um conjunto de *pixels*, ou seja, pequenos blocos que contém informações como a cor ou a intensidade luminosa em uma determinada posição da imagem.

Existem diversas formas de representar um *frame* quanto ao espaço de cores o que é facilmente tratado pelo pacote *OpenCV* (do inglês, *Open Source Computer Vision Library*) que fora utilizado na presente dissertação. A mais comum delas é o espaço de cores RGB (do inglês, Red-Green-Blue) no qual cada *pixel* é representado por um conjunto de três componentes: um vermelho, um verde e um azul, cada um com valores variando de 0 a 255 dependendo da intensidade da cor.

Para a detecção de linhas de transmissão uma operação usual é a adoção do espaço de cores cinza (LIU et al., 2019) que compacta os três canais do espaço RGB em um canal unitário no qual o valor 0 representa a cor preta enquanto 255 indica a cor branca. Esta transformação pode ser representada pela Equação 3.14:

$$f(i, j) = R(i, j) * 0.299 + G(i, j) * 0.587 + B(i, j) * 0.114 \quad (3.14)$$

Na qual $f(i, j)$ é a representação matricial da imagem em cinza e as matrizes $R(i, j)$, $G(i, j)$ e $B(i, j)$ indicam os valores de cada canal de cores. Uma das vantagens dessa operação é a redução do esforço computacional dada a redução da quantidade de

informações da imagem em uma escala de 3:1. A Figura 24 apresenta um exemplo desta mudança.

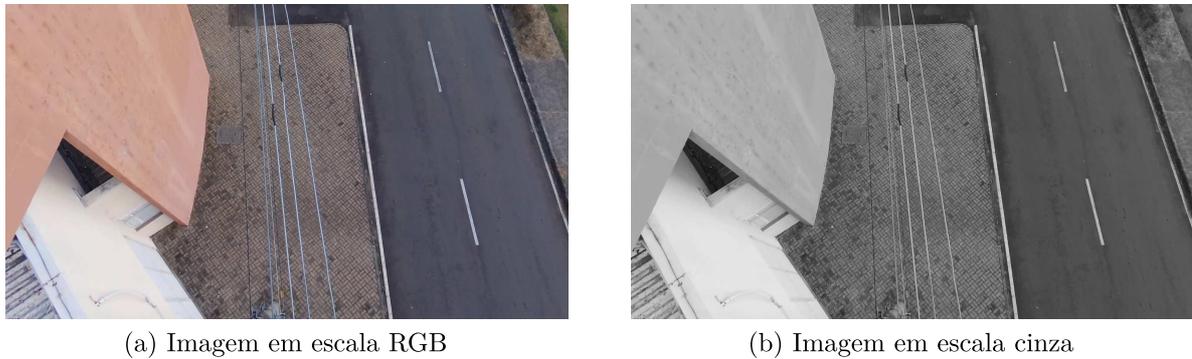


Figura 24 – Transformação do espaço de cores. Fonte: do autor.

A detecção de bordas baseia-se na identificação de linhas que representam a transição de um conjunto de pixel com valores de intensidade similares. Imagens de ambientes reais apresentam muitos detalhes o que leva os algoritmos a detectarem bordas que em muitas aplicações são indesejadas (ruídos). Uma das alternativas para remoção destes ruídos é o desfoque gaussiano (do inglês, *Gaussian Blur*), um filtro passa-baixa que tem como objetivo suavizar a transição de cores e, por consequência, reduzir a detecção de pequenas bordas que podem ser tratadas como *outliers*. A Figura 25 mostra um exemplo do processo.

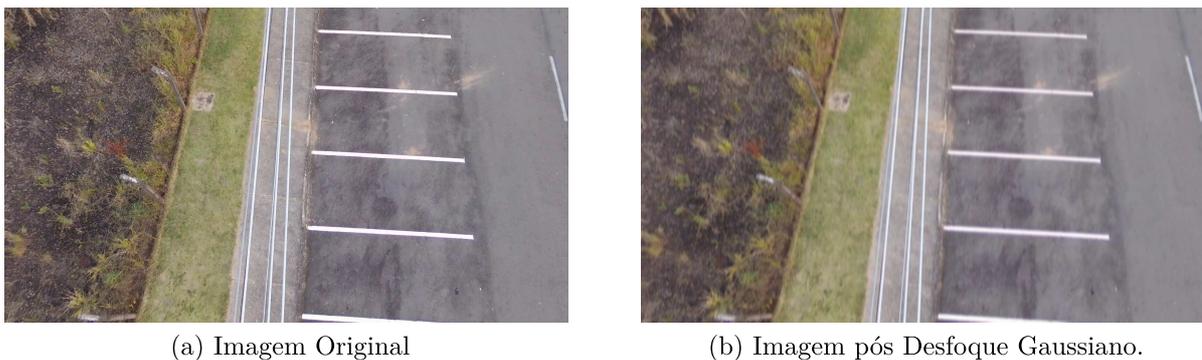


Figura 25 – Processo de Desfoque Gaussiano. Fonte: do autor.

Em seguida é realizado a detecção dos contornos da imagem. Este processo é realizado em duas etapas. Inicialmente, a imagem em escala cinza é passada pelo Operador Sobel (do inglês, *Sobel Operator*), que realiza a convolução dos *pixels* por duas matrizes, uma para cada direção, de forma com que a saída seja uma aproximação do gradiente da imagem que apresenta regiões onde existe uma variação na tonalidade de cores e a direção desta variação o que indica a presença de contornos. A Figura 25 mostra o gradiente da imagem nas direções X e Y .



(a) Imagem Original



(b) Gradiente na direção X.

(c) Gradiente na direção Y.

Figura 26 – Aplicação do Operador Sobel. Fonte: do autor.

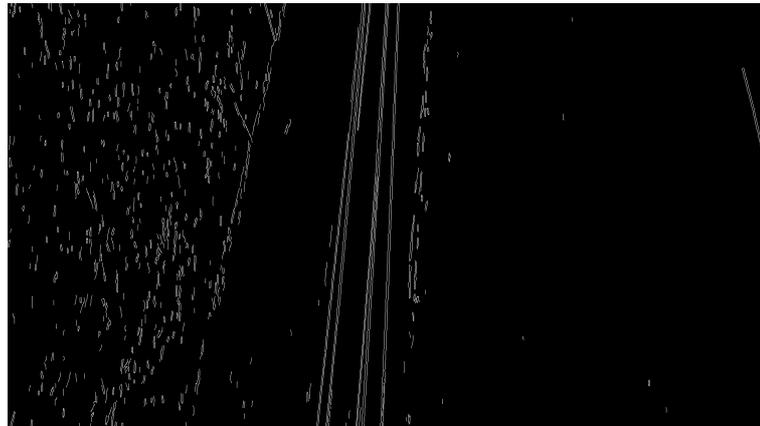


Figura 27 – Detector de Bordas Canny. Fonte: do autor.

Dependendo da aplicação, existe a alternativa da combinação da representação dos gradientes em uma única imagem. Para o presente trabalho, no qual existe um conhecimento prévio da direção das linhas de transmissão na imagem, é realizado a supressão do gradiente na direção X . Por fim, o gradiente escolhido é passado pelo Detector de Bordas Canny, cujo princípio de funcionamento é mostrado na Seção 2.3.1. O resultado do processo é mostrado na Figura 27. O diagrama da Figura 28 sumariza a etapas de processamento de imagem realizadas nesta dissertação.

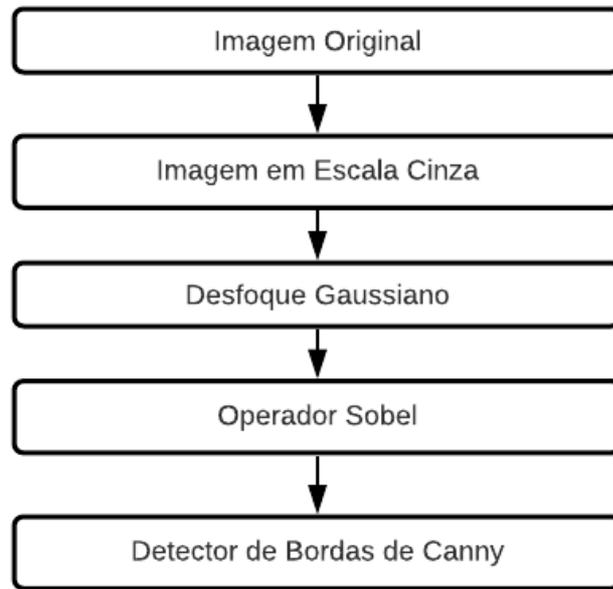


Figura 28 – Diagrama do Processamento de Imagem. Fonte: do autor.

3.3 Detecção das linhas

A imagem precursora da Figura 26 e resultado do detector Canny exemplificado pela Figura 27 representa o estágio inicial e final da etapa de tratamento da imagem, respectivamente. Percebe-se que, no fim, as linhas de transmissão se destacam na figura, embora ainda existam elementos ruidosos.

O próximo passo é a aplicação da Transformada de Hough para identificação das linhas. Vale salientar que esta é uma técnica de detecção genérica que não distingue as linhas de transmissão de elementos como marcações no asfalto e construções retilíneas. A Figura 29 apresenta um exemplo de detecção de linhas em uma imagem real.

Como pode ser visto, as linhas de transmissão foram detectadas de forma correta apesar da presença de *outliers*. O efeito dessas retas não desejadas no cálculo da trajetória pode ser mitigado através do emprego de uma técnica de ajuste de curvas robusta.

3.4 Ajuste de modelos aplicado ao cálculo de trajetórias

Uma vez que o VANT deve seguir as linhas de transmissão em ambientes que contenham diversos elementos retilíneos, é necessário uma estimativa fiel da trajetória a ser seguida de forma com que o mesmo não se desestabilize ou adote um caminho indesejado. Para esta dissertação, a estratégia adotada é a utilização de uma única trajetória retilínea que represente o conjunto de linhas de transmissão eliminando o efeito de retas espúrias

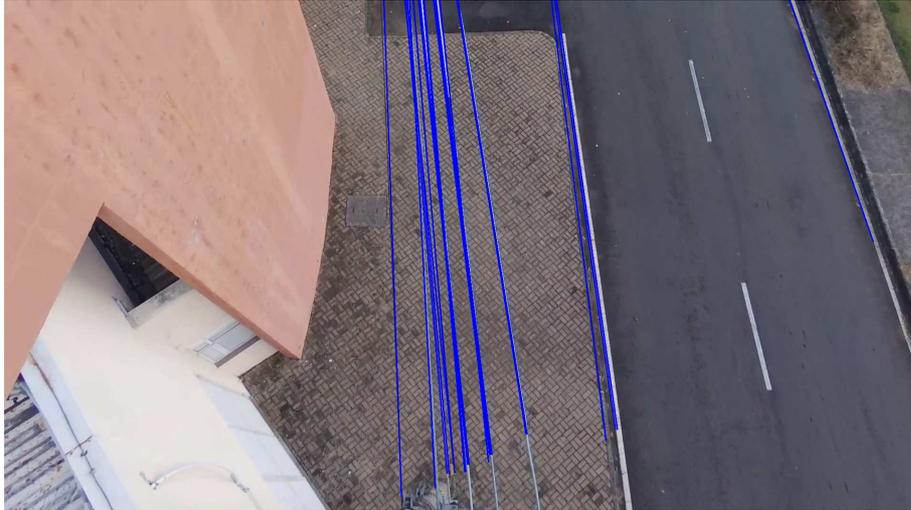


Figura 29 – Aplicação da Transformada de Hough. Fonte: do autor.

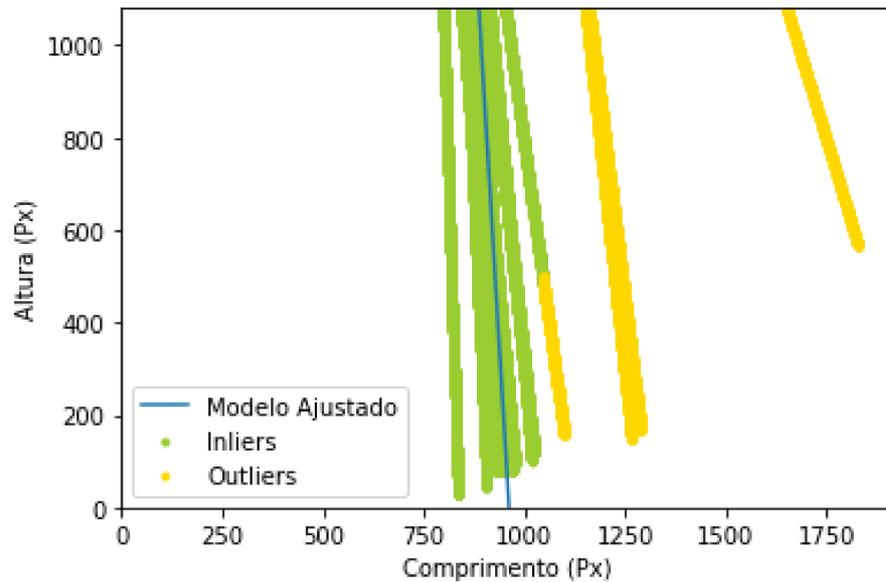


Figura 30 – Ajuste de Modelo: Método RANSAC. Fonte: do autor.

através de técnicas de ajuste de curvas.

Através das linhas detectadas pela Transformada de Hough, conforme exemplificado na Figura 29, é criada uma imagem binária na qual os *pixels* em branco representam o conjunto de pontos a serem utilizados pelas técnicas que visam ajustar os dados de acordo com o modelo escolhido (Para este trabalho, um polinômio de primeira ordem). A Figura 30 apresenta um exemplo de estimação da reta correspondente aos pontos obtidos pela Transformada de Hough através do método RANSAC, que classifica os pontos em *inliers* (Pontos verdes) e *outliers* (Pontos amarelos).

3.5 Controlador NMPC

Como mostrado na seção 2.4.1 a ideia do controlador NMPC conforme o termo preditivo sugere é determinar as variáveis de saída da planta baseando-se no estado atual do sistema e no modelo cinemático do mesmo através da resolução de um problema de otimização cujo o objetivo é minimizar as variáveis de estado que, neste trabalho, estão relacionadas com os erros de seguimento de acordo com a Equação 3.11. Assim, um conjunto de variáveis de controle é computado ao longo de um horizonte de predição finito e somente o primeiro valor é empregado ao VANT. Em seguida os valores dos estados são atualizados e o processo continua de acordo com a frequência de controle escolhida.

O conjunto função objetivo e restrições elementares adotado neste trabalho é apresentado pelas Equações 3.15 à 3.20.

$$J = \min_{u_e} \int_t^{t+T_p} (x_e^T Q x_e + u_e^T R u_e) d\tau + \frac{1}{2} x_e(t+T_p)^T P x_e(t+T_p) \quad (3.15)$$

Sujeito a :

$$\dot{x}_e(\tau) = f(x_e(\tau), u_e(\tau)), \quad (3.16)$$

$$u_e(\tau) \in \nu, \quad (3.17)$$

$$x_e(\tau) \in \chi, \quad (3.18)$$

$$x_e(t + T_p) \in \xi, \quad (3.19)$$

$$T_o = 0, T_p = T_c \quad (3.20)$$

Em que T_p é o Horizonte de predição, T_c é o horizonte de controle, ν e χ são os conjunto de valores admissíveis para os estados e para saída, T_c é o horizonte de controle, ξ é o conjunto de valores factíveis para o estado terminal, Q e R são matrizes positivas definidas que ponderam o custo de estágio e P é uma matriz positiva definida que pondera o custo terminal.

O problema de otimização apresentado acima foi modelado através do pacote *ACADO Toolkit* (HOUSKA; FERREAU; DIEHL, 2011), uma ferramenta *Open Source* que implementa o controlador NMPC através da discretização do modelo por meio do Método de disparo único (do inglês, *Single-shooting method*) no qual um integrador é utilizado para simular as equações dinâmicas do sistema (LEINEWEBER et al., 2003). Em seguida, o OCP (do inglês, *Optimum Control Problem*) é resolvido através do *solver*

qpOASES, que utiliza de uma estratégia de programação quadrática baseada no algoritmo de conjunto ativo paramétrico. Desta forma, determina-se o valor de saída ótima u_{opt} que está relacionada com a variável de controle a ser enviada ao VANT através da Equação 3.13.

3.6 Interface ROS

A comunicação entre os sistemas vitais (sensores e atuadores) do VANT é realizada através da plataforma ROS, uma estrutura de código aberto que contém diversas ferramentas que auxiliam na operação de sistemas robóticos. Seu princípio de funcionamento baseia-se na topologia *peer-to-peer* na qual processos denominados nós comunicam-se entre si através de um nó-mestre de maneira independente. Esta comunicação é realizada através de mensagens que são enviadas por meio de tópicos. Um determinado nó publica um dado (a leitura de um sensor, por exemplo) a um tópico por meio de uma mensagem. Outro nó que necessita deste dado se inscreve ao tópico correspondente e recebe a informação sem que haja a comunicação direta entre estes nós.

Para o presente trabalho a integração entre o drone DJI Tello e a plataforma ROS é realizada através do pacote *tello-driver-ros*, que se comunica com o drone através do *Tello SDK*, um conjunto de ferramentas utilizadas para a programação e controle do VANT. Com o *driver* configurado o nó de controle é capaz de comunicar com o VANT. Este nó se inscreve nos tópicos correspondentes à câmera e ao sensor IMU (do inglês, *Inertial Measurement Unit*) que publicam as informações visuais e posicionais do robô. Com estes dados o algoritmo realiza o processamento da imagem e o cálculo da ação de controle e, por fim, publica um comando de velocidade linear (v_x) e angular (φ_r) no tópico */tello/cmd-vel*.

A Figura 31 mostra uma representação gráfica do funcionamento do algoritmo através da plataforma ROS no qual o parâmetro */line_follower* representa o nó de controle que se comunica com o *drone* Tello através dos tópicos (itens retangulares) e com o nó do otimizador. Vale salientar que o algoritmo proposto nesta dissertação atua como uma malha externa, determinando os valores de v_x e φ_r necessários para manter o VANT alinhado à trajetória. As outras posições e altitude do veículo são geridos através de um controlador interno embutido no mesmo.

4 RESULTADOS E DISCUSSÕES

Este capítulo contém análises referentes à diferentes técnicas de segmentação de imagens, detecção de retas e ajuste de curvas para a resolução do problema de cálculo de trajetórias para o seguimento de linhas de transmissão. Em seguida, são realizados testes práticos em um ambiente controlado. Por fim, o método proposto é empregado em vídeos contendo linhas de transmissão em ambientes reais. Vale salientar que para os testes em ambientes internos foi adotado o drone DJI Tello pelo seu tamanho reduzido e praticidade de implementação. Já para gravação dos vídeos das linhas de transmissão foi escolhido o drone Parrot Bebop uma vez que o mesmo é mais robusto e adequado para ambientes externos além de melhor resolução de imagem se comparado ao DJI Tello.

Todos os testes realizados neste capítulo foram realizados em um computador Intel Core i7 7500U com 8 GB de memória RAM e placa gráfica NVIDIA GeForce 940MX de 2 GB. O sistema operacional escolhido foi o Linux Ubuntu 18.04 com a versão do ROS *Melodic*.

Para os testes das técnicas de segmentação e detecção das linhas, foi elaborado um banco de figuras contendo 225 imagens aéreas de linhas de transmissão, sendo algumas destas retiradas de um banco de dados disponibilizado pelo trabalho de (ZHANG et al., 2019) e outras de autoria própria, em diversos cenários. As imagens utilizadas para as comparações desta seção podem ser acessadas através do *link* :

- <https://github.com/guiaugustoga987/Transmission-Line-Dataset>

Para avaliação dos métodos foi escolhido a Taxa de Acurácia (TA), Taxa de Precisão (TP) e Sensibilidade (S), que podem ser calculadas de acordo com as Equações 4.2, 4.3 e 4.4 :

$$Total = VP + FN \quad (4.1)$$

$$TA = \frac{VP}{Total + FP} \quad (4.2)$$

$$TP = \frac{VP}{VP + FP} \quad (4.3)$$

$$S = \frac{VP}{Total} \quad (4.4)$$

Em que VP (verdadeiro-positivo), é quantidade de linhas corretamente detectadas, FP (falso-positivo) são linhas detectadas que não correspondem a linhas de transmissão, FN (falso-negativo) são linhas de transmissão que não foram corretamente detectadas e

Total é a quantidade de linhas anotadas de forma manual. Além disso, foi computado o tempo médio para execução dos métodos em cada imagem, considerando o *hardware* utilizado.

4.1 Análise quantitativa dos métodos de detecção das linhas

Para comparação das técnicas de detecção de retas aplicadas às linhas de transmissão, foram escolhidos dois métodos: A Transformada de *Hough* clássica e a Transformada de *Hough* Kernelizada (KHT). Para manter a comparação idônea, o Detector de Bordas Canny foi escolhido para a etapa de segmentação da imagem para ambos os casos, com os valores de limiares máximos e mínimos determinados pelo Método de Otsu. Os resultados para as métricas de acurácia e o tempo de execução dos métodos podem ser vistos na Tabela 3.

É possível notar pelos valores elevados de *TP* que os dois métodos conseguiram detectar as linhas de maneira satisfatória embora a quantidade de falsos-positivos seja considerável. Isso se dá pelo fato de se tratarem de métodos genéricos que não diferenciam linhas de transmissão para outros elementos lineares. O método KHT se mostrou o mais eficiente devido aos maiores valores de *TA*, *TP* e *S*, além do menor tempo de execução.

Tabela 3 – Comparação dos métodos de detecção de linhas

Método	Total	<i>VP</i>	<i>FP</i>	<i>S</i>	<i>TA</i>	<i>TP</i>	<i>t</i> (s)
Hough	596	546	83	0.916	0.804	0.862	0.039 ±0.018
KHT	596	565	73	0.947	0.844	0.885	0.022 ±0.018

4.2 Análise quantitativa das técnicas de segmentação de linhas

Para a comparação das técnicas de segmentação de imagens, foram escolhidos quatro métodos: O Detector Canny, LSD, PCNF e ED. As imagens segmentadas foram utilizadas pelo detector de linhas KHT e os resultados podem ser observados na Tabela 4.

Tabela 4 – Comparação dos métodos de segmentação de imagens

Método	Total	<i>VP</i>	<i>FP</i>	<i>S</i>	<i>TA</i>	<i>TP</i>	<i>t</i> (s)
PCNF	596	522	114	0.875	0.735	0.82	0.023 ±0.011
Canny	596	565	73	0.947	0.844	0.886	0.0011 ±0.0004
ED	596	564	76	0.946	0.839	0.881	0.075 ±0.02
LSD	596	561	144	0.941	0.75	0.795	0.12 ±0.04

A partir dos dados apresentados, é possível notar que as técnicas LSD, ED e Canny apresentaram taxas de precisão próximas embora a primeira apresente a acurácia reduzida e o maior tempo de execução. Ao comparar os resultados dos métodos ED e Canny

percebe-se que a diferença se dá principalmente no esforço computacional reduzido para o segundo, o que é uma característica importante para aplicações em tempo real com limitação de *hardware*.

4.3 Análise quantitativa das técnicas de ajuste de curvas

Após a segmentação da imagem e a detecção das linhas o passo final para a estimação da trajetória é ajustar os pontos detectados em uma única curva. Nesta etapa, as imagens foram segmentadas através do método Canny e as linhas foram detectadas através do método KHT. Em seguida, a imagem binária contendo as linhas detectadas foi aplicada em 4 diferentes técnicas de ajuste de curvas: Método dos Mínimos Quadrados (OLS), RANSAC, Regressor de Theil-Sen e Regressor de Huber. O parâmetro de comparação utilizado foi a Raíz do Erro Médio Quadrático (do inglês, *Root Mean Squared Error*) (RMSE) entre a curva obtida e uma curva manualmente inferida (em *pixels*) que representa um *ground truth*, através da Equação 4.5, além do tempo médio de execução. O RMSE foi calculado para todas as imagens e o valor médio é apresentado. Inicialmente, foi escolhido um conjunto de 68 imagens que não apresentam *outliers* (todas as linhas detectadas correspondem as linhas de transmissão). Os resultados obtidos são apresentados na Tabela 5.

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N_{img}} (\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2)}{N_{img}}} \quad (4.5)$$

Em que n é o número de amostras da curva, Y_i é o vetor de valores observados, \hat{Y}_i é o vetor de valores previstos e N_{img} é o número de imagens.

Tabela 5 – Comparação dos métodos de ajuste de curvas sem *outliers*

Método	RMSE	t (s)
OLS	2.75 ±1.15	0.0004 ±0.0001
RANSAC	2.75 ±1.15	0.005 ±0.0007
Huber	3.06 ±1.55	0.015 ±0.004
Theil-Sen	9.27 ±7.31	1.65 ±0.60

Pelos dados apresentados é possível observar que, para cenários sem *outliers* tanto o método OLS quanto o RANSAC realizam o mesmo ajuste, sendo o OLS realizado em menor tempo. O regressor Huber apresentou um resultado ligeiramente inferior aos dois primeiros tanto na métrica RMSE tanto no tempo de execução enquanto a técnica Theil-Sen não se mostrou adequada para resolução do problema proposto devido o valor elevado de RMSE se comparado aos três primeiros.

Em seguida, com o intuito de demonstrar o efeito de linhas espúrias na eficiência das técnicas foram adicionadas 33 imagens contendo *outliers* na detecção das linhas totalizando

101 imagens e as mesmas métricas foram utilizadas para as comparações. Os resultados são apresentados na Tabela 6.

Tabela 6 – Comparação dos métodos de ajuste de curvas com *outliers*

Método	RMSE	t (s)
OLS	4.89 \pm 4.17	0.0004 \pm 0.00007
RANSAC	4.12 \pm 2.30	0.0055 \pm 0.0009
Huber	4.84 \pm 3.50	0.0147 \pm 0.0038
Theil-Sen	11.51 \pm 10.30	1.60 \pm 0.54

A adição de imagens contendo linhas detectadas que não representam as linhas de transmissão, como esperado, afetou a eficiência dos métodos apresentados o que pode ser observado pelo aumento considerado da média da métrica RMSE e do desvio padrão das amostras. Os métodos RANSAC e Huber apresentaram os melhores resultados, com o primeiro sendo o melhor considerando a métrica RMSE e o desvio padrão além do tempo de execução. Isso pode ser explicado pela capacidade de ambos de minimizar o efeito de dos *outliers*: O RANSAC através da sub-amostragem dos dados e o Huber através da penalização dos pontos considerados ruidosos. Para este segundo conjunto, a técnica OLS apresentou um aumento considerável no RMSE além de uma grande dispersão nos valores. Isso se dá uma vez que esta técnica trata todos os pontos com o mesmo peso portanto *outliers*, principalmente aqueles distantes do conjunto de linhas de transmissão, afetam a curva inferida. A técnica Theil-Sen, por sua vez, apresentou o pior desempenho tanto em tempo de execução tanto com o RMSE. Vale salientar que este aumento de RMSE e a maior dispersão dos valores indicam uma piora gradativa das técnicas conforme são adicionados casos nos quais as técnicas de supressão de ruídos não são capazes de limitar a detecção de outros elementos retilíneos. Este é, portanto, um ponto a ser explorado em trabalhos futuros uma vez que estimativas errôneas da trajetória podem afetar o desempenho dos controladores em cenários reais.

As figuras 32 e 33 mostram exemplos de ajuste de curva em dois cenários: O primeiro sem dados ruidosos e o segundo com a presença de *outliers*. A linha em roxo representa o *ground-truth* enquanto as linhas vermelha, azul, verde e amarela representam as curvas obtidas pelos métodos OLS, RANSAC, Theil-Sen e Huber respectivamente. No cenário no qual não foram detectadas linhas espúrias os quatro métodos foram capazes de ajustar a curva de maneira satisfatória. Entretanto para o segundo caso, em que uma marcação no asfalto foi detectada, os métodos OLS e Theil-Sen apresentaram curvas deslocadas enquanto para o RANSAC e Huber o ajuste foi realizado com boa acurácia.



Figura 32 – Ajuste de Curvas - Cenário sem *outliers*. Fonte: do autor.

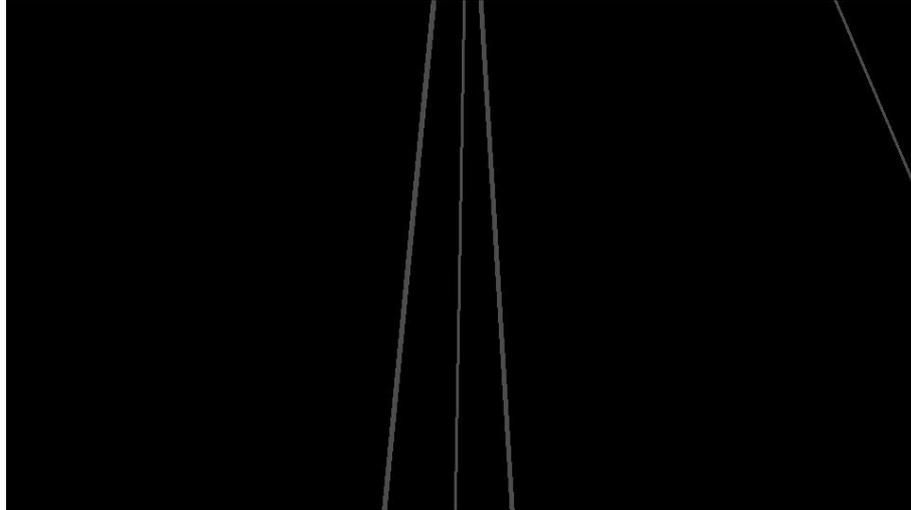
4.4 Testes de seguimento de linhas com o controlador NMPC

Esta seção apresenta os experimentos práticos envolvendo a integração da técnica de estimativa de trajetória com o controle NMPC. Inicialmente, a Figura 34 mostra como as informações visuais são extraídas das imagens para o cálculo do erro lateral Z e angular φ_r que alimentam o controlador no qual a ação ótima a ser executada pelo quadrotor é calculada com uma frequência de 10 Hz que fora escolhida de acordo com o trabalho de (MARIA et al., 2020), que antecedeu a presente dissertação. Esta é uma etapa de suma importância tendo em vista que valores errôneos podem levar o VANT à instabilidade e/ou não conclusão da tarefa. Estas variáveis são calculadas de acordo com as Equações 4.6 e 4.7.

Vale salientar que, para os testes apresentados nessa seção, foi empregado o método de segmentação Canny com a detecção realizada pela Transformada de Hough e a trajetória ajustada através do algoritmo RANSAC.

$$Z = dp \cdot k \quad (4.6)$$

$$\varphi_r = \tan^{-1} \left(\frac{dy}{dx} \right) \quad (4.7)$$



(a) Imagem binária com as linhas detectadas



(b) Curvas detectadas

Figura 33 – Ajuste de Curvas - Cenário com *outliers*. Fonte: do autor.

Em que :

- k : Fator de conversão de *pixels* para metros.
- dp : Distância em *pixels* da trajetória ao centro da imagem.
- dx : Distância longitudinal para cálculo da inclinação da trajetória.
- dy : Distância latitudinal para cálculo da inclinação da trajetória.

Para os testes envolvendo o seguimento de linhas, foi utilizado um VANT do modelo DJI Tello que pode ser visto na Figura 35, em um cenário montado em um ambiente interno composto por um conjunto de cordas com espaçamento entre elas de 12 cm sobrepostas a um tapete que tem como objetivo minimizar o efeito das linhas presentes no piso. De forma a verificar a eficácia do controlador, foi aplicada uma angulação de 40° como mostrado



Figura 34 – Extração das informações visuais da imagem. Fonte: do autor.

na Figura 36. Com isso, o objetivo da missão é manter o VANT com uma velocidade de avanço constante sobre as linhas respeitando as restrições impostas aos erros de estado φ_r e Z , o que significa: manter a linha intermediária no centro da imagem com a orientação perpendicular à porção inferior da mesma.

Assim, quatro configurações foram analisadas, para cada uma delas foram realizados 25 experimentos. Os resultados são apresentados em termos do erro médio quadrático (MSE) que pode ser visto na Tabela 7, da Integral do Erro Absoluto (IAE) que busca comparar a performance do controlador nas diferentes configurações e a Variação Total de Controle (TV) que visa quantificar o efeito de ruídos na ação de controle. As duas últimas métricas são mostradas na Tabela 8. As Figuras 37 a 39 apresentam resultados de um único experimento para as quatro configurações:

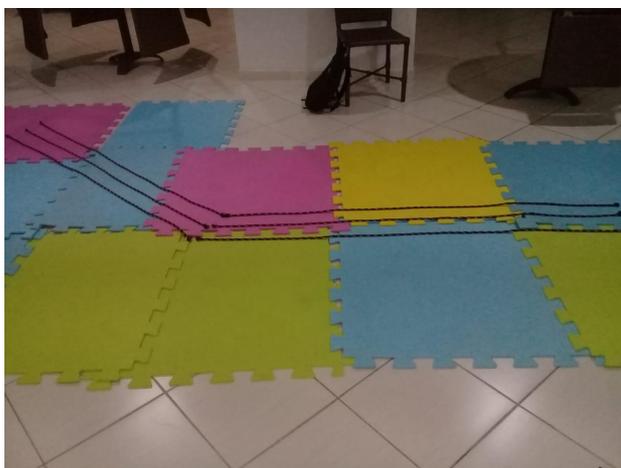
- Configuração I: O VANT inicia o seguimento acima das cordas com $v = 0.1m/s$.
- Configuração II: O VANT inicia o seguimento a uma distância de $20cm$ da corda central com $v = 0.1m/s$.
- Configuração III: O VANT inicia o seguimento acima das cordas com $v = 0.2m/s$.
- Configuração IV: O VANT inicia o seguimento a uma distância de $20cm$ da corda central com $v = 0.2m/s$.

Em todos os casos, o drone inicia o seguimento a uma altura de 1 metro acima das cordas com a orientação paralela as mesmas, ou seja: $\varphi_r = 0$. Para o Controlador NMPC foram escolhidos os seguintes parâmetros :

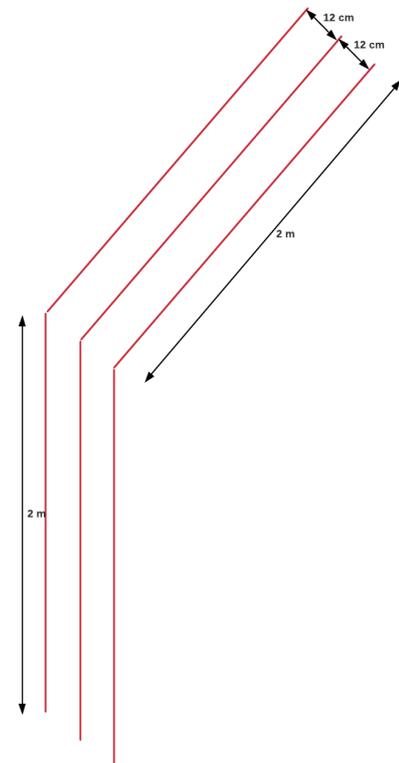
$$Q_i = \text{diagonal}(10, 10); R_i = 25; T_p = T_c = 3; T_s = 0.1s.$$



Figura 35 – Quadrotor DJI Tello. Fonte: amazon.com.br



(a) Cenário dos testes.



(b) Representação gráfica do cenário.

Figura 36 – Ambiente utilizado para os testes de controle. Fonte: do autor.

Com as seguintes restrições elementares :

$$-0,15 \leq z \leq 0,15 \quad (4.8)$$

$$-0,3 \leq \varphi_r \leq 0,3 \quad (4.9)$$

$$-0,35 \leq U_{opt} \leq 0,35 \quad (4.10)$$

Tabela 7 – Erro Médio Quadrático (MSE) e tempo médio para finalização de cada teste.

Configuração	$Z_{MSE}(m)$	$\varphi_{rMSE}(\text{rad/s})$	$U_{optMSE}(\text{rad/s})$	Tempo (s)
I	$4.7e^{-3} \pm 2.6e^{-3}$	$5.6e^{-2} \pm 3.49e^{-2}$	$3.48e^{-2} \pm 2.8e^{-2}$	31.2 ± 3.18
II	$5.9e^{-3} \pm 5.7e^{-3}$	$5.1e^{-2} \pm 3.7e^{-2}$	$3.6e^{-2} \pm 3.4e^{-3}$	30.9 ± 3.52
III	$6.3e^{-3} \pm 4.8e^{-3}$	$1.03e^{-1} \pm 5.45e^{-2}$	$9.5e^{-2} \pm 3.9e^{-2}$	14.9 ± 1.91
IV	$7.7e^{-3} \pm 5.1e^{-3}$	$1.05e^{-1} \pm 3.31e^{-2}$	$1.05e^{-1} \pm 2.8e^{-2}$	14.5 ± 2.24

Tabela 8 – Integral do Erro Absoluto (IAE) e Variação Total de Controle (TV)

Configuração	$Z_{IAE}(m)$	$\varphi_{rIAE}(\text{rad/s})$	$U_{optTV}(\text{rad/s})$
I	1.65 ± 0.46	5.32 ± 1.368	7.55 ± 1.96
II	1.71 ± 0.83	5.1 ± 1.82	7.62 ± 2.78
III	0.89 ± 0.27	3.87 ± 0.8	6.28 ± 1.07
IV	0.98 ± 0.33	3.77 ± 0.63	6.79 ± 1.36

É possível observar pela Tabela 7, que os valores de MSE para as variáveis de estado e para variável de controle são baixas se comparados às restrições impostas ao controlador mesmo para as configurações nas quais o VANT iniciou a trajetória deslocado das cordas. Ao comparar os valores obtidos para configurações com as mesmas velocidades de avanço (I e II/III e IV), percebe-se um aumento nos erros para todos os casos o que se explica pela maior exigência do controlador tendo em vista que o sistema iniciou mais distante da condição de equilíbrio (Valores mínimos de erro, ou seja : $Z = 0$ e $\varphi_r = 0$). Este padrão só não foi observado ao comparar os valores de MSE da variável φ_r para as configurações I e II. Isso se dá devido a maior sensibilidade do cálculo de orientação da trajetória a ruídos se comparado ao erro lateral. Com relação a testes com condições iniciais semelhantes e velocidade de avanço aumentadas (I e III/II e IV) é possível notar o aumento em todas as variáveis devido a uma maior exigência nas ações de controle principalmente no ponto de inflexão da trajetória. Conforme esperado, o tempo médio para realização da cada teste reduziu-se para próximo da metade com o aumento da velocidade para o dobro.

Com relação as métricas IAE e TV é possível verificar que o deslocamento do VANT em 20 cm afetou levemente o IAE para a variável Z o que não foi notado para

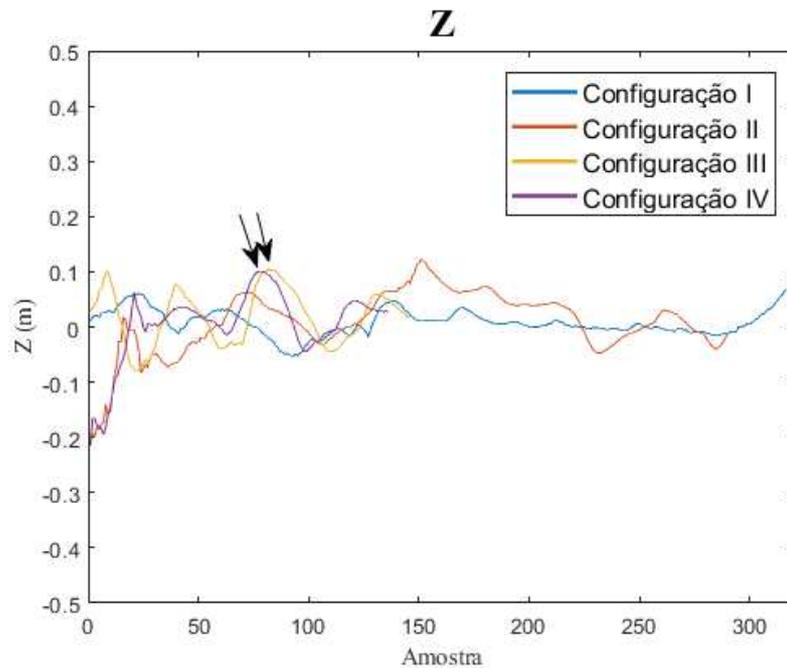


Figura 37 – Resultado Individual - Variável Z . Fonte: do autor.

φ_r . Isso também pode ser explicado pela sensibilidade dessa variável a erros de medição uma vez que seus valores absolutos são bem maiores se comparados ao erro lateral para as quatro configurações. Apesar disso seus valores são próximos a 0, o que mostra que o controlador foi eficaz ao manter o VANT próximo da condição definida independente da posição inicial ou aumento de velocidade. O índice TV sofreu um aumento ao distanciar o VANT da cordas o que mostra que esta ação também aumentou erros nos cálculos das variáveis de estado o que impacta negativamente nas condições impostas para os erros. Vale salientar que, para essas métricas, comparações entre configurações com velocidades diferentes não são pertinentes uma vez que seus valores são influenciados pela quantidade de amostras, diferentemente do MSE que é um valor médio.

A partir do gráfico da Figura 37 é possível notar que o VANT manteve-se próximo às cordas nos quatro casos estudados mesmo quando o mesmo iniciou a trajetória deslocado da corda central. As setas na figura representam o ponto de inflexão da trajetória, conforme mostrado pela Figura 36. Esses picos indicam que o aumento da velocidade afeta o controle em pontos críticos do trajeto, embora o VANT tenha conseguido voltar para a posição desejada. Pela Figura 38 percebe-se que o drone respeitou as restrições para φ_r na maioria do tempo embora existam alguns picos repentinos que indicam erros no cálculo da orientação. Apesar desses erros, o VANT conseguiu concluir os testes sem se perder do referencial. Já pela Figura 39 nota-se que o VANT manteve-se fora da zona de saturação na maior parte do tempo para as configurações I e II enquanto o aumento da velocidade exigiu mais esforço de controle o que pode ser evidenciado pela saturação das

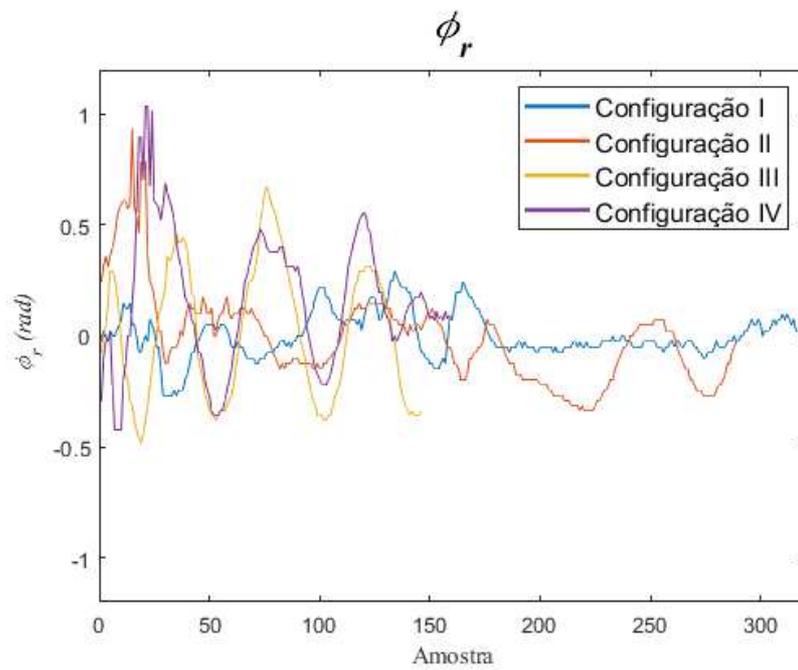


Figura 38 – Resultado Individual - Variável ϕ_r . Fonte: do autor.

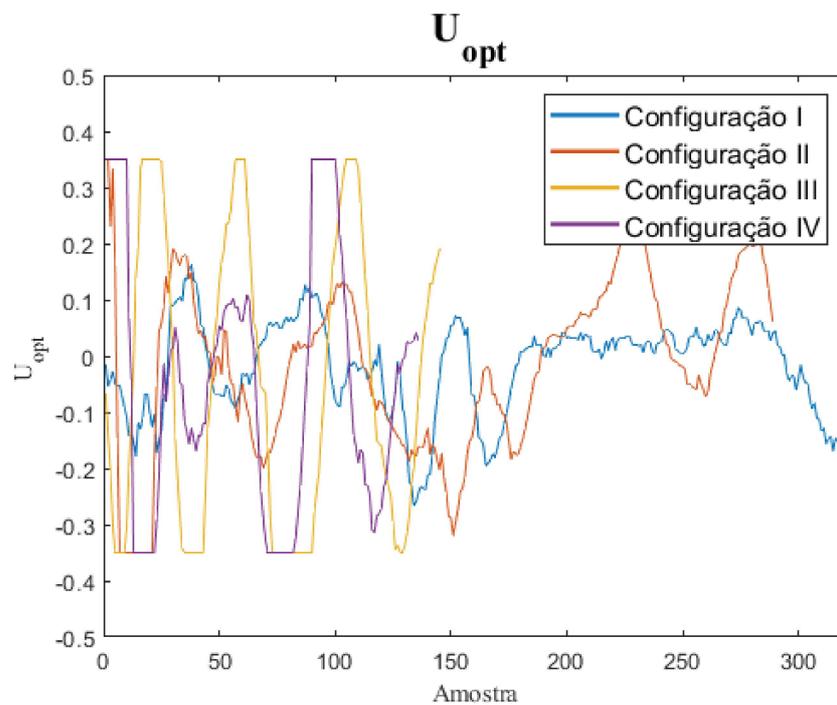


Figura 39 – Resultado Individual - Variável U_{opt} . Fonte: do autor.

curvas III e IV em alguns instantes. É importante frisar que, para as configurações com $v = 0.1m/s$ (I e II) cada teste foi representado por, em média, 320 amostras. Ao aumentar a velocidade (Configurações III e IV), conseqüentemente, foram aferidos menos amostras (155, em média).

4.5 Testes de cálculo de trajetória - Cenários reais

Para os testes referentes ao cálculo de trajetória em ambientes reais, foram extraídos vídeos a partir de voos manuais com o VANT Parrot Bebop em cenários que contém linhas de transmissão e elementos retilíneos como marcações no asfalto e muros de concreto. As linhas foram segmentadas através do método Canny, detectadas pela técnica KHT e ajustadas com o algoritmo RANSAC. Os resultados podem ser vistos através dos seguintes *links*:

- <<https://youtu.be/tcPLBPGVqX8>>
- <<https://youtu.be/qIjV2DRAhUM>>
- <<https://youtu.be/Wf8WaB91Pso>>

Como visto nos vídeos, a trajetória foi estimada de forma satisfatória em grande parte dos *frames*, embora exista uma certa oscilação em alguns trechos. A Figura 40 apresenta exemplos das detecções nestes cenários.

4.6 Conclusões

Este capítulo apresentou resultados referentes a testes envolvendo as diversas etapas da metodologia proposta para estimativa da trajetória e o seguimento de linhas de transmissão. Para as tarefas de identificação das linhas e cálculo da trajetória, as técnicas estudadas foram empregadas em um banco de imagens contendo linhas de transmissão em diversos ambientes. Com relação seguimento das linhas, o controlador escolhido foi testado para duas velocidades de avanço e duas posições iniciais diferentes em um ambiente controlado. Por fim, a estimativa de trajetória foi testada em um vídeo que simula o seguimento de linhas de transmissão.

Com relação a segmentação das imagens, o Detector Canny apresentou os melhores resultados dentre os métodos estudados tanto para as métricas utilizadas quanto para o tempo computacional para execução dos testes. Para etapa de detecção das linhas, a técnica KHT, que foi uma melhoria proposta para a metodologia clássica da Transformada de Hough, apresentou resultados melhores se comparados ao método percursor. Com relação a tarefa de ajuste de curvas, o método iterativo RANSAC foi o que apresentou o menor erro RMSE, comparando-se as curvas obtidas com trajetórias anotadas de forma



(a) Estimação correta.



(b) Estimação com falhas.

Figura 40 – Exemplos de detecção - Cenários reais. Fonte: do autor.

manual embora a adição de imagens com *outliers* tenha afetado o desempenho das técnicas testadas.

Em relação ao seguimento das linhas, o controlador NMPC se mostrou capaz de manter o VANT alinhado com a trajetória em todos as configurações testadas. O aumento da velocidade de avanço e piora das condições iniciais depreciaram a eficiência do controlador embora o mesmo tenha conseguido manter o VANT dentro das restrições impostas inicialmente.

Por fim, os testes envolvendo a detecção das linhas nos vídeos contendo imagens aéreas apresentou resultados satisfatórios na maior partes dos *frames*, sendo capaz de estimar a trajetória que, em um teste prático, deveria ser seguida pelo drone.

5 CONCLUSÃO E TRABALHOS FUTUROS

O presente trabalho visa apresentar um método de estimação visual de trajetória para o seguimento de linhas de transmissão através de VANTs. Inicialmente, as imagens adquiridas por câmeras acopladas aos drones são tratadas e os elementos retilíneos são detectados. Em seguida, as linhas encontradas passam por um algoritmo de ajuste de curvas que tem como objetivo calcular uma única função que representa o conjunto de linhas de transmissão, mitigando o efeito de possíveis elementos ruidosos. Com a trajetória estimada, é possível extrair parâmetros de referência posicional das linhas com relação a câmera que está posicionada na posição central do *frame* do VANT, que alimentam um controlador do tipo NMPC que busca manter o drone alinhado na trajetória estipulada.

Testes foram executados com o objetivo de determinar as técnicas mais adequadas para a segmentação da imagem, detecção das linhas e ajuste de curvas com relação a parâmetros quantitativos e ao tempo de execução tendo em vista a frequência de operação do controlador escolhido. O detector de bordas Canny se mostrou o melhor método para segmentação das linhas com melhores taxas de acurácia (0.844), precisão (0.886) e sensibilidade (0.947) além do menor tempo de execução. Para a detecção das linhas, a técnica KHT, que é uma variante da Transformada de Hough, apresentou melhores resultados nas métricas escolhidas (0.947/0.91, 0.844/0.804 e 0.885/0.862) bem como no tempo de execução. Outra vantagem da técnica é a menor necessidade de ajuste de parâmetros se comparado à Hough na qual os limiares máximos e mínimos para a detecção variam de imagem para imagem. Vale frisar que uma das dificuldades do presente trabalho fora a implementação de técnicas mais eficientes para a detecção das linhas, sem que isso compromettesse a frequência exigida pelo controlador. Um possível caminho seria a implementação de outras técnicas de controle que comportassem abordagens baseadas em aprendizado de máquina, que, invariavelmente requerem um maior esforço computacional. Com relação a estimativa da trajetória, o algoritmo iterativo RANSAC apresentou melhores resultados pela métrica RMSE (4.12) em um banco de imagens contendo linhas de transmissões em cenários reais que podem possuir outros elementos retilíneos que também são detectados pelas técnicas escolhidas. Em cenários ideais, sem ruídos na detecção, as técnicas RANSAC e OLS apresentaram resultados semelhantes (RMSE = 2.75).

Em seguida, a metodologia de estimação de trajetória foi testada em um VANT físico em um cenário controlado contendo cordas que simulam as linhas de transmissão. Para verificar a eficácia do controlador foram escolhidas duas velocidades de avanço e duas condições de posições iniciais para o VANT com relação as linhas. Em todos os casos, o drone conseguiu seguir a trajetória com relação as restrições de estado impostas ao controlador sem grandes oscilações na variável de controle. Para uma maior velocidade

de avanço, como esperado, foi exigido mais do controlador o que foi traduzido em maiores valores de erro nos estados do sistema (De $4.7e^{-3}$ para $4.7e^{-3}$ com relação ao erro Z e $5.6e^{-2}$ para $1.03e^{-1}$ na variável φ_r , se comparadas as configurações I e III), o que não impossibilitou o seguimento. Por fim, o algoritmo proposto foi aplicado em vídeos contendo imagens aéreas de linhas de transmissão capturadas por um VANT guiado de forma manual. Os resultados mostram que a trajetória foi estimada com boa acurácia em grande parte dos *frames* embora exista uma pequena oscilação em alguns trechos causada pela detecção de retas que não correspondem a linhas de transmissão ou a não detecção das mesmas em certos *frames*.

Com relação a trabalhos futuros, uma alternativa é a escolha de técnicas robustas para a detecção de linhas de transmissão como metodologias baseadas em aprendizado de máquina, que permitam a diferenciação destas linhas em relação a outros elementos retilíneos, permitindo que a trajetória seja inferida de maneira correta mesmo em casos em que hajam detecções de linhas espúrias. Para isso também é necessário a mudança da técnica de controle empregada tendo em vista o maior tempo que essas técnicas necessitam para a detecção dos objetos. Outra sugestão é a utilização de sensores a laser em conjunto às imagens ou o uso de câmeras de profundidade além de plantas georreferenciadas das linhas, permitindo uma maior acurácia na detecção e distância do VANT com relação as linhas. Além disso, a metodologia empregada nesta dissertação pode ser testada para o seguimento em ambientes reais com a presença de distúrbios como o vento e diferentes cenários de iluminação. Para isso, outro ponto que deve ser estudado é a possível interferência eletromagnética dos cabos de alta tensão, que pode afetar no envio de dados entre o computador e o VANT e na leitura dos sensores do mesmo.

REFERÊNCIAS

- ABBASI, E.; GHAYOUR, M.; DANESH, M. Virtual leader-follower formation control of multi quadrotors by using feedback linearization controller. In: IEEE. *2017 5th RSI International Conference on Robotics and Mechatronics (ICRoM)*. [S.l.], 2017. p. 614–619.
- AKINLAR, C.; TOPAL, C. Edlines: A real-time line segment detector with a false detection control. *Pattern Recognition Letters*, Elsevier, v. 32, n. 13, p. 1633–1642, 2011.
- ALHASSAN, A. B. et al. Power transmission line inspection robots: A review, trends and challenges for future research. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 118, p. 105862, 2020.
- ALLGOWER, F. et al. Nonlinear model predictive control: From theory to application. *Journal-Chinese Institute Of Chemical Engineers*, CHINESE INST CHEM ENGINEERS, v. 35, n. 3, p. 299–316, 2004.
- ALTAN, A.; HACIOĞLU, R. Model predictive control of three-axis gimbal system mounted on uav for real-time target tracking under external disturbances. *Mechanical Systems and Signal Processing*, Elsevier, v. 138, p. 106548, 2020.
- ANTHONY, D. et al. On crop height estimation with uavs. In: IEEE. *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems*. [S.l.], 2014. p. 4805–4812.
- ANWEILER, S.; PIWOWARSKI, D. Multicopter platform prototype for environmental monitoring. *Journal of Cleaner Production*, Elsevier, v. 155, p. 204–211, 2017.
- BAI, W. et al. Transmission line voltage classes identification based on particle swarm optimization algorithm and pcnn. *Ferroelectrics*, Taylor & Francis, v. 521, n. 1, p. 6–17, 2017.
- BISTA, S. R.; GIORDANO, P. R.; CHAUMETTE, F. Appearance-based indoor navigation by ibvs using line segments. *IEEE robotics and automation letters*, IEEE, v. 1, n. 1, p. 423–430, 2016.
- BORASE, R. P. et al. A review of pid control, tuning methods and applications. *International Journal of Dynamics and Control*, Springer, v. 9, n. 2, p. 818–827, 2021.
- BUFFI, G. et al. Survey of the ridracoli dam: Uav-based photogrammetry and traditional topographic techniques in the inspection of vertical structures. *Geomatics, natural hazards and risk*, Taylor & Francis, v. 8, n. 2, p. 1562–1579, 2017.
- CERÓN, A.; MONDRAGÓN, I.; PRIETO, F. Onboard visual-based navigation system for power line following with uav. *International Journal of Advanced Robotic Systems*, SAGE Publications Sage UK: London, England, v. 15, n. 2, p. 1729881418763452, 2018.
- CHEN, H. et al. From automation system to autonomous system: An architecture perspective. *Journal of Marine Science and Engineering*, Multidisciplinary Digital Publishing Institute, v. 9, n. 6, p. 645, 2021.
- CHENG, H.; YANG, Y. Model predictive control and pid for path following of an unmanned quadrotor helicopter. In: IEEE. *2017 12th IEEE conference on industrial electronics and applications (ICIEA)*. [S.l.], 2017. p. 768–773.

- CHITYALA, R.; PUDIPEDDI, S. *Image processing and acquisition using Python*. [S.l.]: Chapman and Hall/CRC, 2020.
- CUI, J. et al. Path planning algorithms for power transmission line inspection using unmanned aerial vehicles. *2017 29th Chinese Control And Decision Conference (CCDC)*, p. 2304–2309, 2017.
- DENG, C. et al. Real time autonomous transmission line following system for quadrotor helicopters. In: IEEE. *2016 International Conference on Smart Grid and Clean Energy Technologies (ICSGCE)*. [S.l.], 2016. p. 61–64.
- DERPANIS, K. G. Overview of the ransac algorithm. *Image Rochester NY*, v. 4, n. 1, p. 2–3, 2010.
- ELÉTRICA, E.; SILVA, M. F. da. Filtro de kalman estendido com o modelo da interferência eletromagnética de linhas de transmissao aplicada a veículos autônomos aéreos. 2017.
- ELLOUMI, M. et al. Monitoring road traffic with a uav-based system. In: IEEE. *2018 IEEE Wireless Communications and Networking Conference (WCNC)*. [S.l.], 2018. p. 1–6.
- ERDELJ, M. et al. Uavs that fly forever: Uninterrupted structural inspection through automatic uav replacement. *Ad Hoc Networks*, Elsevier, v. 94, p. 101612, 2019.
- FALANGA, D. et al. Pampc: Perception-aware model predictive control for quadrotors. In: IEEE. *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. [S.l.], 2018. p. 1–8.
- FERNANDES, L. A.; OLIVEIRA, M. M. Real-time line detection through an improved hough transform voting scheme. *Pattern recognition*, Elsevier, v. 41, n. 1, p. 299–314, 2008.
- FINDEISEN, R.; ALLGÖWER, F. An introduction to nonlinear model predictive control. In: CITESEER. *21st Benelux meeting on systems and control*. [S.l.], 2002. v. 11, p. 119–141.
- FISCHLER, M. A.; BOLLES, R. C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, ACM New York, NY, USA, v. 24, n. 6, p. 381–395, 1981.
- FORGÁČ, R.; MOKRIŠ, I. Formal representation of images by pulse coupled neural networks. In: *3rd Slovakian-Hungarian Joint Symposium on Applied Machine Intelligence*. [S.l.: s.n.], 2005. p. 107–114.
- GIOI, R. G. V. et al. Lsd: a line segment detector. *Image Processing On Line*, v. 2, p. 35–55, 2012.
- GRANATO, G.; LINE, K.-T. R. A visual basic program for calculating and graphing robust nonparametric estimates of linear regression coefficients between two continuous variables. *Techniques and Methods of the US Geological Survey, book*, v. 4, p. 1–31, 2006.
- HAMIDI, K. E. et al. Neural network and fuzzy-logic-based self-tuning pid control for quadcopter path tracking. *Studies in Informatics and Control*, v. 28, n. 4, p. 401–412, 2019.

- HANSEN, P. C.; PEREYRA, V.; SCHERER, G. *Least squares data fitting with applications*. [S.l.]: JHU Press, 2013.
- HE, T.; ZENG, Y.; HU, Z. Research of multi-rotor uavs detailed autonomous inspection technology of transmission lines based on route planning. *IEEE Access*, IEEE, v. 7, p. 114955–114965, 2019.
- HOUSKA, B.; FERREAU, H. J.; DIEHL, M. An auto-generated real-time iteration algorithm for nonlinear mpc in the microsecond range. *Automatica*, Elsevier, v. 47, n. 10, p. 2279–2285, 2011.
- HUANG, T. et al. Fuzzy sliding mode control for a quadrotor uav. In: IEEE. *2019 IEEE 8th Data Driven Control and Learning Systems Conference (DDCLS)*. [S.l.], 2019. p. 672–677.
- HUI, X. et al. Vision-based autonomous navigation approach for unmanned aerial vehicle transmission-line inspection. *International Journal of Advanced Robotic Systems*, SAGE Publications Sage UK: London, England, v. 15, n. 1, p. 1729881417752821, 2018.
- JIANG, J. et al. Fault diagnosis of the bushing infrared images based on mask r-cnn and improved pcnn joint algorithm. *High voltage*, Wiley Online Library, 2020.
- JIANG, S. et al. Uav-based oblique photogrammetry for outdoor data acquisition and offsite visual inspection of transmission line. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 9, n. 3, p. 278, 2017.
- KUMAR, V.; NAKRA, B.; MITTAL, A. A review on classical and fuzzy pid controllers. *International Journal of Intelligent Control and Systems*, v. 16, n. 3, p. 170–181, 2011.
- LEINWEBER, D. B. et al. An efficient multiple shooting based reduced sqp strategy for large-scale dynamic process optimization. part 1: theoretical aspects. *Computers & Chemical Engineering*, Elsevier, v. 27, n. 2, p. 157–166, 2003.
- LI, Y. et al. Power line detection by pyramidal patch classification. *IEEE Transactions on Emerging Topics in Computational Intelligence*, IEEE, v. 3, n. 6, p. 416–426, 2018.
- LI, Z. et al. Towards automatic power line detection for a uav surveillance system using pulse coupled neural filter and an improved hough transform. *Machine Vision and Applications*, Springer, v. 21, n. 5, p. 677–686, 2010.
- LIN, C.-L.; SU, C.-Y. Modified unsharp masking detection using otsu thresholding and gray code. *2016 IEEE International Conference on Industrial Technology (ICIT)*, p. 787–791, 2016.
- LINDQVIST, B. et al. Nonlinear mpc for collision avoidance and control of uavs with dynamic obstacles. *IEEE Robotics and Automation Letters*, IEEE, v. 5, n. 4, p. 6001–6008, 2020.
- LIU, Y. et al. Uav transmission line inspection object recognition based on mask r-cnn. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2019. v. 1345, n. 6, p. 062043.

- LOPEZ-FRANCO, C. et al. Visual servoing for an autonomous hexarotor using a neural network based pid controller. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 17, n. 8, p. 1865, 2017.
- LUGO-CÁRDENAS, I.; SALAZAR, S.; LOZANO, R. Lyapunov based 3d path following kinematic controller for a fixed wing uav. *IFAC-PapersOnLine*, Elsevier, v. 50, n. 1, p. 15946–15951, 2017.
- LUO, X. et al. Object-aware power line detection using color and near-infrared images. *IEEE Transactions on Aerospace and Electronic Systems*, IEEE, v. 50, n. 2, p. 1374–1389, 2014.
- LUO, Y.; YU, X.; YANG, D. A new recognition algorithm for high-voltage lines based on improved lsd and convolutional neural networks. *IET Image Processing*, Wiley Online Library, 2021.
- MANSOURI, S. S. et al. Cooperative uavs as a tool for aerial inspection of the aging infrastructure. In: SPRINGER. *Field and Service Robotics*. [S.l.], 2018. p. 177–189.
- MARIA, T. H. S. et al. Nmpc controller applied to an uav path following problem. In: IEEE. *2020 Latin American Robotics Symposium (LARS), 2020 Brazilian Symposium on Robotics (SBR) and 2020 Workshop on Robotics in Education (WRE)*. [S.l.], 2020. p. 1–6.
- MARTINS, V. et al. *Implementação de um sistema de controle para seguimento de linhas de transmissão utilizando um vant*. Tese (Doutorado) — Master's thesis, Universidade Federal do Espírito Santo, 2015.
- MEHNDIRATTA, M. et al. Robust tracking control of aerial robots via a simple learning strategy-based feedback linearization. *IEEE Access*, IEEE, v. 8, p. 1653–1669, 2019.
- MOFID, O.; MOBAYEN, S. Adaptive sliding mode control for finite-time stability of quad-rotor uavs with parametric uncertainties. *ISA transactions*, Elsevier, v. 72, p. 1–14, 2018.
- MU, B.; PEI, Y.; SHI, Y. Integral sliding mode control for a quadrotor in the presence of model uncertainties and external disturbances. In: IEEE. *2017 American Control Conference (ACC)*. [S.l.], 2017. p. 5818–5823.
- NAJM, A. A.; IBRAHEEM, I. K. Nonlinear pid controller design for a 6-dof uav quadrotor system. *Engineering Science and Technology, an International Journal*, Elsevier, v. 22, n. 4, p. 1087–1097, 2019.
- NASCIMENTO, I. B. et al. Nmpc strategy for a quadrotor uav in a 3d unknown environment. In: IEEE. *2019 19th International Conference on Advanced Robotics (ICAR)*. [S.l.], 2019. p. 179–184.
- NASSERI, M. et al. Power line detection and tracking using hough transform and particle filter. In: IEEE. *2018 6th RSI International Conference on Robotics and Mechatronics (IcRoM)*. [S.l.], 2018. p. 130–134.
- OTHMAN, Z.; ABDULLAH, A. An adaptive threshold based on multiple resolution levels for canny edge detection. In: SPRINGER. *International Conference of Reliable Information and Communication Technology*. [S.l.], 2017. p. 316–323.

- OWEN, A. B. A robust hybrid of lasso and ridge regression. *Contemporary Mathematics*, Providence, RI: American Mathematical Society, v. 443, n. 7, p. 59–72, 2007.
- POULIOT, N.; RICHARD, P.-L.; MONTAMBAULT, S. Linescout technology opens the way to robotic inspection and maintenance of high-voltage power lines. *IEEE Power and Energy Technology Systems Journal*, IEEE, v. 2, n. 1, p. 1–11, 2015.
- RAFIQUE, M. A.; LYNCH, A. F. Output-feedback image-based visual servoing for multirotor unmanned aerial vehicle line following. *IEEE Transactions on Aerospace and Electronic Systems*, IEEE, v. 56, n. 4, p. 3182–3196, 2020.
- RAJ, J.; RAGHUWAIYA, K. S.; VANUALAILAI, J. Novel lyapunov-based autonomous controllers for quadrotors. *IEEE Access*, IEEE, v. 8, p. 47393–47406, 2020.
- RAO, V. P. S.; RAO, G. S. Design and modelling of an affordable uav based pesticide sprayer in agriculture applications. In: IEEE. *2019 Fifth International Conference on Electrical Energy Systems (ICEES)*. [S.l.], 2019. p. 1–4.
- REN, H. et al. A review of uav monitoring in mining areas: Current status and future perspectives. *International Journal of Coal Science & Technology*, Springer, v. 6, n. 3, p. 320–333, 2019.
- RIBEIRO, T. T.; CONCEIÇÃO, A. G. Nonlinear model predictive visual path following control to autonomous mobile robots. *Journal of Intelligent & Robotic Systems*, Springer, v. 95, n. 2, p. 731–743, 2019.
- ROQUE, P. et al. Fast model predictive image-based visual servoing for quadrotors. In: IEEE. *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. [S.l.], 2020. p. 7566–7572.
- RUBÍ, B.; PÉREZ, R.; MORCEGO, B. A survey of path following control strategies for uavs focused on quadrotors. *Journal of Intelligent & Robotic Systems*, Springer, v. 98, n. 2, p. 241–265, 2020.
- SANTOS, T. et al. Plined: Vision-based power lines detection for unmanned aerial vehicles. In: IEEE. *2017 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)*. [S.l.], 2017. p. 253–259.
- SAWADSITANG, S. et al. Joint ground and aerial package delivery services: A stochastic optimization approach. *IEEE Transactions on Intelligent Transportation Systems*, IEEE, v. 20, n. 6, p. 2241–2254, 2018.
- SHUAI, C. et al. Power lines extraction and distance measurement from binocular aerial images for power lines inspection using uav. In: IEEE. *2017 9th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*. [S.l.], 2017. v. 2, p. 69–74.
- SILVA, M. F. da et al. Unmanned aerial vehicle for transmission line inspection using an extended kalman filter with colored electromagnetic interference. *ISA transactions*, Elsevier, v. 100, p. 322–333, 2020.
- TAKAYA, K. et al. Development of uav system for autonomous power line inspection. In: IEEE. *2019 23rd International Conference on System Theory, Control and Computing (ICSTCC)*. [S.l.], 2019. p. 762–767.

- TOSATO, P. et al. An autonomous swarm of drones for industrial gas sensing applications. In: IEEE. *2019 IEEE 20th International Symposium on "A World of Wireless, Mobile and Multimedia Networks" (WoWMoM)*. [S.l.], 2019. p. 1–6.
- UZAKOV, T.; NASCIMENTO, T. P.; SASKA, M. Uav vision-based nonlinear formation control applied to inspection of electrical power lines. In: IEEE. *2020 International Conference on Unmanned Aircraft Systems (ICUAS)*. [S.l.], 2020. p. 1301–1308.
- WANG, B.; CHEN, L.; WANG, M. Novel image segmentation method based on pcnn. *Optik*, Elsevier, v. 187, p. 193–197, 2019.
- WANG, Y. et al. Vector field based sliding mode control of curved path following for miniature unmanned aerial vehicles in winds. *Journal of Systems Science and Complexity*, Academy of Mathematics and Systems Science, Chinese Academy of Sciences, v. 31, n. 1, p. 302–324, 2018.
- WU, G. et al. A novel self-navigated inspection robot along high-voltage power transmission line and its application. In: SPRINGER. *International Conference on Intelligent Robotics and Applications*. [S.l.], 2008. p. 1145–1154.
- YETGIN, Ö. E.; GEREK, Ö. N. Pld: Power line detection system for aircrafts. In: IEEE. *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*. [S.l.], 2017. p. 1–5.
- ZHANG, H. et al. Detecting power lines in uav images with convolutional features and structured constraints. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 11, n. 11, p. 1342, 2019.
- ZHANG, X. et al. An automatic acquisition algorithm for power distribution line based on vehicle-mounted system. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Tenth International Conference on Digital Image Processing (ICDIP 2018)*. [S.l.], 2018. v. 10806, p. 108066Q.
- ZHAO, K. et al. Deep hough transform for semantic line detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, 2021.
- ZHAO, L. et al. Power line extraction from aerial images using object-based markov random field with anisotropic weighted penalty. *IEEE Access*, IEEE, v. 7, p. 125333–125356, 2019.
- ZHENG, D. et al. Image-based visual servoing of a quadrotor using virtual camera approach. *IEEE/ASME Transactions on Mechatronics*, IEEE, v. 22, n. 2, p. 972–982, 2016.
- ZHU, M. et al. Multi-uav rapid-assessment task-assignment problem in a post-earthquake scenario. *IEEE access*, IEEE, v. 7, p. 74542–74557, 2019.
- ZORMPAS, A. et al. Power transmission lines inspection using properly equipped unmanned aerial vehicle (uav). In: IEEE. *2018 IEEE International Conference on Imaging Systems and Techniques (IST)*. [S.l.], 2018. p. 1–5.