

RAFAEL MONTEIRO JORGE ALVES DE SOUZA

**SISTEMA DE IDENTIFICAÇÃO DE FONTE DE GÁS
UTILIZANDO NANOQUADRICÓPTERO**



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA

2022

RAFAEL MONTEIRO JORGE ALVES DE SOUZA

**SISTEMA DE IDENTIFICAÇÃO DE FONTE DE GÁS
UTILIZANDO NANOQUADRICÓPTERO**

Tese apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de **DOCTOR EM CIÊNCIAS**.

Banca Examinadora:

Aniel Silva de Moraes, Dr. (Orientador) - UFU

Daniel Costa Ramos, Dr. - UFU

Renato Ferreira Fernandes Júnior, Dr. - UFU

Aline Fernanda Bianco Mattioli, Dr^a. - CEFET MG

Henrique José Avelar, Dr. - CEFET MG

UBERLÂNDIA – MG

2022

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

S729 Souza, Rafael Monteiro Jorge Alves de, 1989-
2022 Sistema de Identificação de Fonte de Gás Utilizando
Nanoquadricóptero [recurso eletrônico] / Rafael Monteiro
Jorge Alves de Souza. - 2022.

Orientador: Aniel Silva de Moraes.

Coorientador: Luis Cláudio Oliveira Lopes.

Tese (Doutorado) - Universidade Federal de Uberlândia,
Pós-graduação em Engenharia Elétrica.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.te.2022.496>

Inclui bibliografia.

Inclui ilustrações.

1. Engenharia elétrica. I. Moraes, Aniel Silva de,
1979-, (Orient.). II. Lopes, Luis Cláudio Oliveira, 1964-
, (Coorient.). III. Universidade Federal de Uberlândia.
Pós-graduação em Engenharia Elétrica. IV. Título.

CDU: 621.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Engenharia Elétrica
 Av. João Naves de Ávila, 2121, Bloco 3N - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4707 - www.posgrad.feelt.ufu.br - copel@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Tese de Doutorado, 303, PPGEELT				
Data:	Vinte e seis de agosto de dois mil e vinte e dois	Hora de início:	14:00	Hora de encerramento:	17:10
Matrícula do Discente:	11713EEL011				
Nome do Discente:	Rafael Monteiro Jorge Alves de Souza				
Título do Trabalho:	Sistema de identificação de fonte de gás utilizando nanoquadricóptero				
Área de concentração:	Sistemas de energia elétrica				
Linha de pesquisa:	Controle e Automação				
Projeto de Pesquisa de vinculação:	Coordenador do projeto: Aniel Silva de Moraes Título do projeto: Controle Cooperativo de Enxame de Veículos Aéreos não Tripulados Especializados no Monitoramento e Detecção de Falhas na Indústria 4.0. Agência financiadora: CNPq Número do processo na agência financiadora: 403054/2021-4 Vigência do projeto: de 17/03/2022 a 31/03/2025.				

Reuniu-se por meio de videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Daniel Costa Ramos - FEELT/UFU; Renato Ferreira Fernandes Junior - FEELT/UFU; Aline Fernanda Bianco Mattioli - CEFET-MG; Henrique José Avelar - CEFET-MG; Aniel Silva de Moraes - FEELT/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Aniel Silva de Moraes, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Aniel Silva de Morais, Professor(a) do Magistério Superior**, em 26/08/2022, às 17:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Daniel Costa Ramos, Professor(a) do Magistério Superior**, em 26/08/2022, às 17:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Renato Ferreira Fernandes Junior, Professor(a) do Magistério Superior**, em 26/08/2022, às 17:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Aline Fernanda Bianco Mattioli, Usuário Externo**, em 30/08/2022, às 12:15, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Henrique José Avelar, Usuário Externo**, em 30/08/2022, às 12:31, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3788729** e o código CRC **59852B0C**.

*À Irene, Eliana, Rosana e Gabriela, professoras
da minha vida.*

AGRADECIMENTOS

Agradeço aos professores Aniel Silva de Moraes e Luís Cláudio de Oliveira Lopes pela grande oportunidade de aprendizado, além da compreensão, confiança e direcionamentos fornecidos durante a execução, sem os quais este trabalho não teria acontecido.

Estendo os meus agradecimentos a todos os professores que tive em minha carreira acadêmica, desde o primeiro ano antes da pré-escola até hoje, em especial àqueles que até hoje me inspiram na carreira e como ser humano.

Aos meus familiares, avós, tios, tias, primos e primas que, em suas particularidades, sempre me inspiraram companheirismo e altruísmo.

Particularmente à minha avó Irene cujo exemplo e busca incessante pelo conhecimento tornaram-se referência para minha escolha profissional.

Aos meus pais Eliana e Júlio e meu irmão Lucas pelos ensinamentos e lições de superação que são minha fonte de motivação na busca por desafios e na força de vontade para superá-los.

À Gabriela, minha companheira, pelo carinho, compreensão e apoio que me deram o suporte emocional necessário para este desafio, estando comigo nos melhores e piores momentos possíveis, além do apoio técnico e capacidade de organização ímpares. Esta conquista também é sua.

Aos meus amigos com os quais sei que posso sempre contar, não importando a dificuldade, em especial ao Evandro, Frederico, Marcos e Cláudio pela compreensão neste período de aprendizagem.

Aos meus companheiros de trabalho pela paciência e suporte ao longo dos anos de desenvolvimento deste projeto, em especial à Nazareth, Maria Aparecida, Ana, Valquíria e aos gestores da Faculdade de Engenharia Civil desta Universidade que sempre me acolheram

prontamente e permitiram que este trabalho se desenvolvesse com o mínimo de empecilhos, em especial nas figuras dos Professores Dogmar, Paulo, Marcio Salla, Marcio Schmidt e Gregório.

Ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Uberlândia pela oportunidade de aperfeiçoamento, a todos os técnicos pela atenção e prontidão nos procedimentos juntos à secretaria do programa.

Finalmente agradeço à Universidade Federal de Uberlândia que ofereceu esta oportunidade e tantas outras, através das quais pude me desenvolver profissionalmente e pessoalmente.

“Não se pode criar experiência. É preciso passar por ela.

[Albert Camus]

RESUMO

Soluções para o problema de detecção de fonte de odor são necessárias para permitir a realização de diversas tarefas como busca por vazamentos ambientais de gás, monitoramento da qualidade do ar e detecção de presença de gás tóxico em ambientes internos, permitindo, assim, aumentar a segurança e prevenir acidentes em ambientes com presença de gases perigosos. Neste sentido, a utilização de aeronaves nesta tarefa agrega agilidade, segurança e eficiência, contribuindo no desenvolvimento da Indústria 4.0. A solução presente neste trabalho faz uso de uma estratégia de busca pela fonte de odor utilizando a abordagem do mapeamento da distribuição de gás em um ambiente tridimensional utilizando um nanoquadricóptero do modelo *Crazyflie 2.0*. O mapeamento é viabilizado a partir de uma função de densidade de probabilidade por kernel gaussiano, a qual atua sobre as leituras de características extraídas do sinal de qualidade do ar de um sensor SGP30 embarcado e produz um mapa contínuo, sem haver necessidade de segmentação do ambiente. A subtarefa de declaração da posição da fonte é avaliada através de diferentes estratégias envolvendo redes neurais artificiais e técnicas de aprendizagem de máquina. Os resultados apontam que o algoritmo proposto é capaz de realizar estimativas precisas sobre a localização da fonte com erros de estimação com média próxima a 0,46 m em um ambiente de aproximadamente 15 m³. O algoritmo possui a possibilidade de escalabilidade para incorporar outras aeronaves e explorar ambientes internos com maiores volumes.

Palavras-Chave: Localização de fonte de odor, mapeamento de distribuição de gás, quadricóptero, redes neurais artificiais, aprendizagem de máquina, estimação de densidade de probabilidade, Crazyflie 2.0

ABSTRACT

Solutions to the odor source localization problem are necessary to allow accomplishment of several tasks such as environmental gas leakage searching, air quality monitoring and indoor detection of dangerous gas, thus allowing to increase safety and prevent accidents in environments where hazardous gases are handle. In this sense, the use of aircraft in this task brings agility, safety and efficiency, contributing to the development of Industry 4.0. The solution presented in this work makes use of an odor source localization strategy by gas distribution mapping approach in a three-dimensional environment using a Crazyflie 2.0 nano quadcopter. The mapping is constructed from a probability density function by Gaussian kernel, which acts over characteristics extracted from the air quality signal of an on-board SGP30 sensor and produces a continuous map, without the need for segmentation of the workspace. The source position declaration subtask is evaluated through different strategies involving artificial neural networks and machine learning techniques. The results show that the proposed algorithm is capable of making accurate estimates of the odor source location with estimation errors means close to 0.46 m in an environment of approximately 15 m³. The algorithm has the possibility of scalability by incorporation other aircraft and thus explore indoor environments with higher volumes.

Keywords: Odor source localization, gas distribution mapping, quadcopter, artificial neural network, machine learning, probability density estimation, Crazyflie 2.0

LISTA DE FIGURAS

Figura 1.1 - Diagrama esquemático de um quadricóptero.....	02
Figura 1.2 - a) Fumaça e vapor de água lançados de um avião; b) Exemplo ilustrativo típico da indicação da concentração de odor medida no tempo ou no espaço.....	04
Figura 3.1 - Quadricóptero <i>Crazyflie 2.0</i>	26
Figura 3.2 - Arquitetura do sistema do <i>Crayflie 2.0</i>	26
Figura 3.3 - Posicionamento dos nós no ambiente.....	29
Figura 3.4 - Sensor de temperatura e umidade DHT11.....	31
Figura 3.5 - Placa contendo o sensor SGP30.....	33
Figura 4.1 - a) <i>Crazyflie</i> com a <i>tag</i> do sistema de posicionamento e o sensor de gás; b) conexão do sensor ao terminal de ligação.....	35
Figura 4.2 - Fluxograma do firmware desenvolvido.....	36
Figura 4.3 - a) Dispositivo para distribuição do gás com predomínio da dispersão; b) dispositivo para distribuição com predomínio de turbulência.....	37
Figura 4.4 - Configuração do espaço de trabalho.....	37
Figura 4.5 - Interface da aplicação para testes do sensor.....	39
Figura 4.6 - Comportamento do sinal de TVOC a diferentes valores de <i>baseline</i>	42
Figura 4.7 - Influência da ventoinha e hélices na média e variância do sinal por <i>baseline</i>	43
Figura 4.8 - Comportamento temporal do sinal de TVOC em função da distância até a fonte.....	45
Figura 4.9 - Ensaios para a determinação da característica a ser utilizada na estimação da posição da fonte de gás.....	47
Figura 4.10 - Infográfico do algoritmo de redução de volume de busca.....	49
Figura 4.11 - Influência do valor da variável de suavização da função de estimação de densidade por kernel.....	53
Figura 4.12 - Simulador de dispersão de odor simplificado, não observadas proporções.....	55
Figura 5.1 - Demonstração gráfica do ensaio 7.....	59
Figura 5.2 - Evolução do erro de estimativa durante o ensaio 7.....	59
Figura 5.3 - Demonstração gráfica do ensaio 5.....	60

Figura 5.4 - Evolução do erro de estimativa durante o ensaio 5.....	61
----------------------------------------------------------------------------	----

LISTA DE TABELAS

Tabela 3.1 - Parâmetros físicos do <i>Crazyflie 2.0</i>	29
Tabela 3.2 - Especificações dos sinais medidos e processados do sensor SGP30.....	32
Tabela 4.1 - Posição das âncoras no espaço de trabalho.....	38
Tabela 4.2 - Resultados das estratégias de treinamento.....	56
Tabela 5.1 - Sumário dos resultados dos ensaios.....	58
Tabela 5.2 - Apresentação dos resultados.....	63
Tabela 5.3 - Erros do treinamento dos algoritmos inteligentes.....	65
Tabela 5.4 - Erros médios de estimação para cada abordagem.....	66

LISTA DE QUADROS

Quadro 2.1 - Soluções para o problema do rastro gerado pelas hélices.....	22
Quadro 2.2 - Abordagem do mapeamento como solução ao problema da localização da fonte de odor.....	23

LISTA DE SÍMBOLOS

m	Massa total do quadricóptero
b	Coefficiente de empuxo dos rotores
d	Coefficiente de arrasto das hélices
l	Distância entre os rotores e o centro de massa do veículo
ϕ	Ângulo de rolagem
θ	Ângulo de arfagem
ψ	Ângulo de guinada
I_{xx}, I_{yy}, I_{zz}	Momentos de inércia sobre os eixos x, y, z
$\hat{f}_h(x)$	Função de densidade estimada
n	Quantidade de amostras
x_i	População de amostras extraídas
h	Parâmetro de suavização
K	Função de Kernel
μ	Média
σ	Desvio padrão
σ^2	Variância
BW	Largura de banda

LISTA DE ABREVIATURAS

CG	Centro de Gravidade
DoF	<i>Degree of Freedom</i> – Graus de Liberdade
EKF	<i>Extended Kalman Filter</i> – Filtro de Kalman Estendido
GPS	<i>Global Positioning System</i> – Sistema de Posicionamento Global
IMU	<i>Inertial Measurement Unit</i> – Unidade de Medição Inercial
KDE	<i>Kernel Density Estimation</i> – Estimação de Densidade por Kernel
LFO	Localização de Fonte de Odor
MOX	<i>Metal Oxide</i> – Óxido de Metal
PSO	<i>Particle Swarm Optimization</i> – Otimização por Enxame de Partículas
PPB	Partes por bilhão
PPM	Partes por milhão
RNA	Rede Neural Artificial
RMSGB	Regressor de Múltiplas Saídas Baseado em Gradiente <i>Boosting</i>
RNAPM	Rede Neural Artificial <i>Perceptron</i> Multicamadas
SVM	<i>Support-Vector Machine</i> – Máquina de Vetores de Suporte
TDoA	<i>Time Difference of Arrive</i> – Diferença de Tempo de Chegada
TVOC	Total de Compostos Orgânicos Voláteis
TWR	<i>Two Way Ranging</i> – Em dois sentidos
VANT	Veículo Aéreo Não Tripulado
VTOL	<i>Vertical Take-off and Landing</i> – Decolagem e Pouso Vertical

SUMÁRIO

1. INTRODUÇÃO.....	01
1.1. Visão Geral.....	01
1.2. Definição do Problema.....	03
<i>1.2.1. Recursos On-board Limitados e Baixa Carga Útil.....</i>	<i>06</i>
<i>1.2.2. Características Dinâmicas da Resposta dos Sensores de Gás.....</i>	<i>07</i>
<i>1.2.3. Influência das Hélices.....</i>	<i>09</i>
1.3. Justificativa.....	09
1.4. Objetivos.....	11
1.5. Organização Geral.....	11
2. ESTADO DA ARTE.....	13
2.1. Veículos Aéreos na Tarefa de Localização de Fonte de Odor.....	13
2.2. Mapeamento do Ambiente Utilizando Extrapolação por Kernel Gaussiano para Detecção da Fonte de Odor.....	17
2.3. Algoritmos de Aprendizagem para Declaração da Fonte de Gás.....	19
2.4. Conclusão.....	21
3. MATERIAIS.....	24
3.1. Crazyfly 2.0.....	25
<i>3.1.1. Microcontroladores.....</i>	<i>27</i>
<i>3.1.2. Unidade de Medição Inercial.....</i>	<i>27</i>
<i>3.1.3. Motores e Hélices.....</i>	<i>27</i>
<i>3.1.4. Bateria.....</i>	<i>28</i>

3.1.5. Comunicação.....	28
3.1.6. Parâmetros Físicos.....	28
3.2. Sistema de Posicionamento.....	29
3.3. Sensor de Temperatura e Umidade.....	30
3.4. Sensor de Detecção de Gás.....	31
4. METODOLOGIA.....	34
4.1. Interface de Comunicação com o Sensor de Gás.....	34
4.2. Planejamento dos Ensaios.....	36
4.3. Caracterização da Resposta do Sensor.....	40
4.3.1. Influência da Baseline.....	41
4.3.2. Influência da Ventoinha e Hélices.....	43
4.3.3. Análise do Sinal de TVOC.....	44
4.4. Extração de Informações Provenientes da Resposta do Sensor.....	46
4.5. Algoritmo de Busca pela Fonte de Odor.....	48
4.5.1. Trajetória.....	48
4.5.2. Extrapolação por Kernel Gaussiano.....	51
4.5.3. Declaração da Fonte.....	54
5. RESULTADOS E DISCUSSÕES.....	57
5.1. Declaração da Fonte <i>Online</i>.....	57
5.2. Declaração da Fonte <i>Offline</i>.....	63
5.2.1. Treinamento e Seleção pelo Simulador.....	63
5.2.2. Treinamento pelo Simulador e Seleção pelos Dados Experimentais.....	64
5.2.3. Treinamento e Seleção pelos Dados Experimentais.....	64

5.3. Considerações Finais.....	64
6. CONCLUSÃO.....	67
6.1. Trabalhos Futuros.....	69
REFERÊNCIAS BIBLIOGRÁFICAS.....	71

CAPÍTULO 1

INTRODUÇÃO

1.1. Visão Geral

Nos últimos anos, os veículos aéreos não tripulados (VANTs), consolidaram-se como uma importante ferramenta no auxílio de tarefas até então complexas, dispendiosas ou arriscadas para o ser humano.

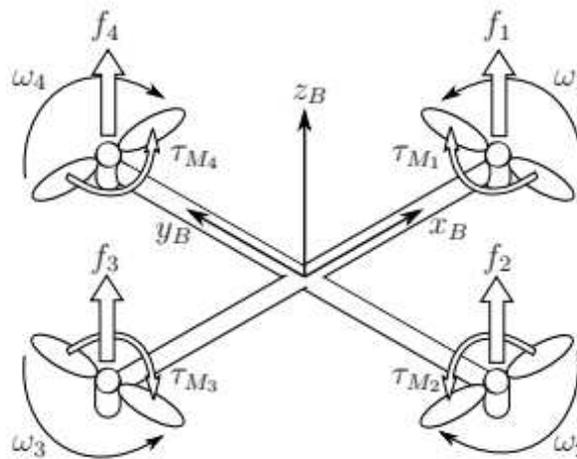
A utilização destes veículos tornou-se viável a partir do desenvolvimento da eletrônica e da robótica, com o advento de atuadores miniaturizados capazes de fornecer uma boa relação de empuxo por unidade de massa, sensores menores e mais precisos, baterias mais leves e duráveis, microcontroladores mais potentes capazes de processar algoritmos complexos e, finalmente, técnicas de controle e estimação mais avançadas.

O estudo realizado por Liew *et al.* (2017) constatou que desde o ano de 2001, houve um significativo aumento de publicações acerca de VANTs nas principais conferências e periódicos de áreas como engenharia de controle, eletrônica embarcada, sistemas autônomos e inteligentes, entre outros. Destas publicações, a grande maioria refere-se aos quadricópteros, o que pode ser justificado devido às vantagens em relação a outras aeronaves autônomas.

Quando comparados com as aeronaves de asa fixa, os quadricópteros apresentam capacidade de efetuar pousos e decolagens verticais (VTOL, do inglês *Vertical Take-off and Landing*), pairagem e possibilidade de voo em locais internos e com obstáculos, embora apresentam menor autonomia. Já em relação a outras aeronaves de asas rotativas, como os helicópteros convencionais, os quadricópteros são mecanicamente mais simples, apresentam elevada manobrabilidade, menor custo de controle e maior capacidade de carga (BOUABDALLAH, 2007).

O quadricóptero, ou quadrirrotor, é uma aeronave pertencente à classe dos veículos aéreos de asas rotativas, munido de quatro conjuntos motor-hélice, cujo princípio de movimento se sustenta no controle da velocidade de rotação de cada conjunto, Figura 1.1.

Figura 1.1 – Diagrama esquemático de um quadricóptero.



Fonte: Adaptado de LUKKONEN (2011).

Por possuir seis graus de liberdade, sendo três relacionados à posição tridimensional do centro de gravidade (x, y, z) e três referentes à atitude (ϕ, θ, ψ) , e apresentar apenas quatro variáveis de controle relacionadas às velocidades de rotação dos motores, o quadricóptero é classificado como um sistema mecânico subatuado.

Ademais, as equações dinâmicas da aeronave demonstram um comportamento inerentemente instável e não-linear. Além disso, o veículo possui características fluidicas volúveis como o comportamento aerodinâmico, tamanho reduzido e peso diminuto, o que torna o sistema desafiador aos desenvolvedores e pesquisadores da área (KEMPER e FATIKOW, 2006).

Deste modo, aplicação de sensores mais precisos, atuadores mais confiáveis e implementação de controladores mais sofisticados tornam os veículos mais estáveis e capazes de realizar tarefas mais complexas que demandam o cumprimento de trajetórias mais agressivas (CASTILHO, LOZANO e DZUL, 2005).

Neste cenário, estudos são publicados anualmente demonstrando aplicações dos quadricópteros em diversas tarefas até então onerosas, inviáveis ou impossíveis de serem realizadas em outras plataformas, dentre elas a tarefa de detecção de fonte de odor.

As aplicações de um sistema de detecção de fonte de odor contemplam diferentes situações. O trabalho realizado por Kovadlo e Russel (2008) propõe encontrar a fonte de substâncias perigosas como materiais biológicos transportados pelo ar e produtos químicos tóxicos em áreas industriais, detecção de materiais como drogas em alfândegas, busca por sobreviventes em prédios afetados por terremotos, deslizamentos ou avalanches, detecção de fogo em estágios iniciais, localizar minas e bombas não detonadas e localizar outros robôs em um enxame.

Na pesquisa realizada por Ishida, Wada e Matsukura (2012), um incidente é reportado no qual um sistema de detecção robótica poderia ter sido utilizado, envolvendo vazamento de gás em área urbana na cidade de Kitami, no Japão, no qual houve 3 mortes. O autor justifica que os alarmes de detecção de gases desligam quando a resposta a uma certa concentração de gás excede o limite de valor preestabelecido.

Em Neumann, Hüllmann e Bartholmai (2019) foi proposta a utilização de um enxame de quadricópteros para o monitoramento da qualidade do ar em áreas internas de plantas industriais, justificando que produtos trazidos pelo ar podem ser um risco à saúde dos trabalhadores. Além disso, especialistas em saúde ocupacional estão altamente interessados em modelos precisos de distribuição de poeira e gás em ambientes laborais.

Isto posto, o desenvolvimento desta tese visa apresentar uma contribuição no contexto do desenvolvimento da Indústria 4.0, ao propor um sistema capaz de elevar o nível de automação nos processos envolvendo segurança em plantas industriais, através de mecanismos autônomos aliados a técnicas inteligentes, com o intuito de detectar a localização de fontes de odor em ambientes internos com o uso de um quadricóptero.

1.2. Definição do Problema

Localização de fonte de odor (LFO) significa encontrar a posição de uma fonte química de interesse dentro de um ambiente através de um rastro, isto é, uma pluma criada pela fonte e influenciada pelo vento (CHEN e HUANG, 2019).

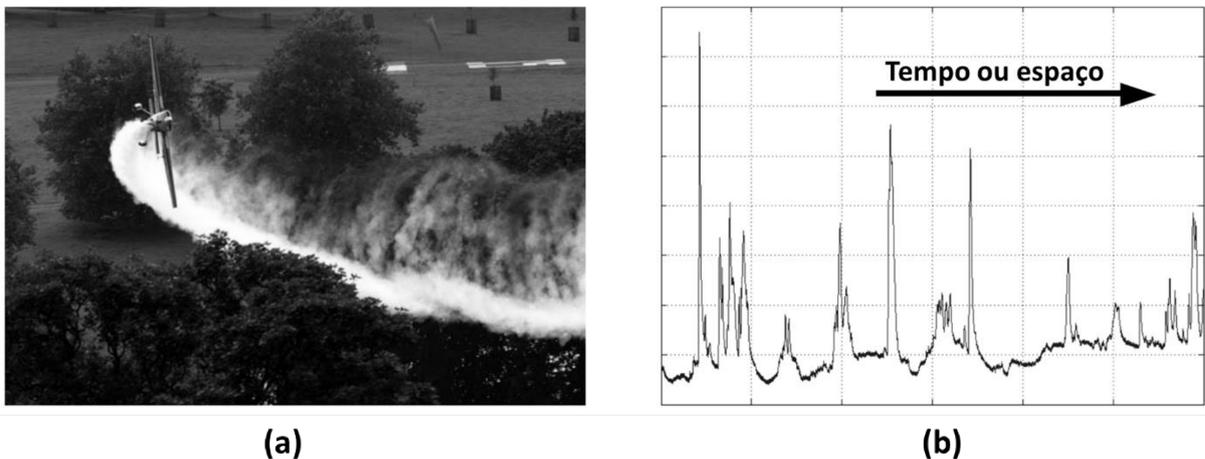
Conforme Bayat *et al.* (2017), o problema da detecção de fonte de odor pode ser abordado de duas maneiras distintas: rede fixa de sensores e robótica móvel. A primeira abordagem refere-se às técnicas em que não há movimento das unidades sensoriais. Basicamente uma rede de sensores é espalhada em posições fixas no ambiente ficando responsável por adquirir os dados de concentração do gás e, através de nós de referência,

estimar a posição da fonte de odor. Esta abordagem traz, como grande desvantagem, o fato de não ser flexível para transporte e rápida utilização em outros locais além do já instalado, inviabilizando emprego em algumas situações. A aplicação de robótica móvel nesta tarefa envolve a utilização de um ou mais agentes equipados com unidades sensoriais, que utilizam diversas técnicas de busca para delimitar a localização de uma fonte de odor, consistindo em uma operação mais dinâmica e flexível em relação aos sistemas de detecção fixos.

Entretanto, a abordagem móvel apresenta diversos desafios relacionados à robustez, planejamento, coordenação, comunicação, cooperação e navegação.

De forma geral, segundo Farrell *et al.* (2002), o maior desafio presente na tarefa de detecção de fonte de odor se deve à estrutura da pluma de dispersão. Devido à natureza turbulenta do ar, a estrutura das plumas possui um padrão irregular de dispersão, tal que o sinal de concentração se altera bruscamente tanto no tempo quanto no espaço, como ilustrado na Figura 1.2.

Figura 1.2 – a) Fumaça e vapor de água lançados de um avião; b) Exemplo ilustrativo típico da indicação da concentração de odor medida no tempo ou no espaço.



Fonte: Extraído de LOCHMATTER (2010).

A tarefa de Localização de Fonte de Odor (LFO) pode ser dividida em três subtarefas: 1) busca pela pluma: navegação que ocorre até que a pluma seja detectada; 2) navegação pela pluma: comportamento predominante depois que a pluma é detectada e 3) declaração da fonte: etapa em que, munido das informações adquiridas nas etapas anteriores, os agentes estimam a posição da fonte de gás no ambiente.

Para efeito didático, neste trabalho serão utilizadas duas taxonomias complementares. A primeira utilizará como critério a estratégia de movimento do veículo mediante a presença da pluma, isto é, quais abordagens os algoritmos empregarão para resolver o problema. Nesta taxonomia, relevando a classificação proposta por Burgués *et al.* (2019), os métodos dividem-se em três grupos: 1) rastreamento em reação à pluma, no qual o veículo empregará trajetórias predefinidas buscando ativamente a posição da fonte de odor, reagindo diretamente aos eventos de detecção de gás; 2) modelagem da pluma, em que o agente busca equilibrar as ações de busca direta pela fonte com a exploração do ambiente e 3) baseados em mapeamento, que ocorre quando o veículo busca maximizar a exploração do ambiente em detrimento de seguir ativamente a fonte, com o objetivo de obter um número grande de amostras para alimentar a construção de um mapa de concentração de odor e a partir deste mapa ser capaz de estimar a posição da fonte.

A segunda taxonomia considerada neste trabalho, tal como apresentada por Jing, Meng e Ishida (2021) propõe classificar as soluções de acordo com o princípio do algoritmo empregado, resultando nas categorias: 1) métodos biomiméticos, 2) métodos heurísticos, 3) métodos de inferência probabilísticas e 4) métodos de aprendizagem.

A primeira categoria, é definida como aquela em que as decisões dos agentes ocorrem de maneira reativa à percepção do gás, sem envolver representações abstratas (modelos) ou mecanismos de memória (ARKIN, 1998). Estes métodos foram, historicamente, os primeiros a serem explorados e dividem-se entre aqueles que fazem uso unicamente das leituras do sensor químico (quimiotaxia), como exemplo os algoritmos estudados em Macedo, Marques e Costa (2019), Anderson *et al.* (2019) e Eu e Yap (2018) e aqueles que utilizam informações sobre o vento (anemotaxia) como em Ishida *et al.* (1994) e Bau e Cardé (2015). À luz destes métodos, a observação do comportamento de seres vivos como reação à presença de pluma no ambiente, trouxe inspiração para o desenvolvimento de técnicas nomeadas biomiméticas ou bioinspiradas, as quais definem uma variedade de movimentos que foram catalogados na natureza e adaptados para a robótica móvel. Como exemplos foram reproduzidos os comportamentos das traças e bichos-da-seda por Shigaki, Fikri e Kurabayashi (2018) e Pyk *et al.* (2006), das lagostas por Grasso *et al.* (1996) e Consi *et al.* (1994), do besouro-do-esterco por Russell *et al.* (2003), das moscas-da-fruta por Miao (2020), das abelhas por Purnamadajaja e Russell (2005), entre outros.

A premissa destes métodos considera que existe um gradiente de concentração em torno da fonte, entretanto, considerando a natureza turbulenta da dispersão de odor, principalmente

em condições de busca utilizando veículos aéreos não tripulados, estes métodos verificaram-se insuficientes para lidar com situações reais.

Os métodos heurísticos compreendem o problema de LFO como um problema de otimização matemática cuja função objetivo é constituída a partir da concentração de odor detectada e a solução é averiguada utilizando algoritmos heurísticos, tais como algoritmos genéticos (MARQUES, NUNES e ALMEIDA, 2002), busca por formação (LI e WU, 2021), otimização por enxame de partículas, referido nesta tese como PSO, do inglês *Particle Swarm Optimization*, (COQUET, ARNOLD e BOUVET, 2021), por colônia de formigas (MA, LIU e XIAO, 2020), por colônia artificial de abelhas (FRONCZEK e PRASAD, 2005), entre outros.

Na categoria dos algoritmos probabilísticos, as soluções incluem a busca pela redução da entropia, como em Vergassola, Villermaux e Shraiman (2007) e Fatés (2016), maximização da informação por Bayat *et al.* (2016), Rodríguez *et al.* (2014) e Crasta *et al.* (2016), inferência Bayesiana como presente em Blanco *et al.* (2013) e Hajieghrary *et al.* (2016), cadeia de Markov por Farrell, Pang e Li (2003), métodos baseados em kernel como em Lilienthal *et al.* (2009) e Reggente e Lilienthal (2010) e métodos de filtro de partículas como observado em Pang e Farrell (2006) e Neumann (2013).

Por fim, os métodos de aprendizagem se caracterizam por aqueles que se valem de alguma estratégia em que o agente aprende através da observação do próprio movimento, ou dos movimentos dos outros agentes, visando melhor desempenho na tarefa. Segundo Jing, Meng e Ishida (2021), embora os métodos de aprendizagem desempenham um meio significativo de auxílio na tarefa de LFO, eles ainda não apresentam soluções completas, sendo, portanto, utilizados como parte de um algoritmo de busca. Como exemplo, o trabalho de Gaurav, Kumar e Singh (2020) utilizou otimização por enxame de partículas aliado a um algoritmo de otimização baseada em aprendizagem e treinamento para localização de múltiplas fontes no ambiente.

Além dos desafios inerentes ao problema de LFO robótica, no caso particular dos robôs aéreos, como os utilizados nesta tese, outros problemas surgem.

1.2.1. Recursos On-board Limitados e Baixa Carga Útil

O primeiro problema refere-se às características físicas da aeronave e principalmente sua capacidade de carga e autonomia. O reduzido valor de carga útil (*payload*) da aeronave utilizada neste projeto (15 g) impossibilita o embarque de uma bateria com maior capacidade,

o que limita o tempo no ar e, assim, impede a adoção de estratégias de busca que demandem maior tempo de voo.

Como consequência, a escolha do sensor de gás utilizado no projeto restringiu-se àqueles que obedecem à três critérios: baixo consumo energético, baixo peso e reduzido tempo de resposta e recuperação.

A inviabilidade de embarcar equipamentos de sensoriamento influencia também nas soluções para o problema de estimação da posição. Com isso, a utilização de câmeras embarcadas, como proposto por Dunkley *et al.* (2014), torna-se inviável, pois além de diminuir a autonomia de voo, por vezes impossibilita o embarque do sensor de gás. Outras soluções para estimação da posição incluem a utilização de sistemas de posicionamento global (GPS) para ambientes externos, e para sistemas internos o uso de sistema de captura de movimento (PREISS *et al.*, 2017) ou baseado em rádio frequência (FARID, NORDIN e ISMAIL, 2013). Neste trabalho, optou-se pela utilização de um sistema de posicionamento local.

1.2.2. Características Dinâmicas da Resposta dos Sensores de Gás

Outro problema que se acentua quando utilizados veículos aéreos na tarefa é o comportamento dinâmico da resposta do sensor de gás. A utilização de sensores baseados em semicondutores de óxido de metal (MOX, do inglês *Metal Oxide*) se tornou a escolha mais popular para utilização em quadricópteros, devido ao seu tamanho reduzido, elevada sensibilidade, baixo custo, além de serem capazes de detectar uma ampla variedade de gases. Entretanto, a utilização destes sensores esbarra em uma questão fundamental, definida por Burgués *et al.* (2019) como o principal problema na detecção de odor por sensores MOX: o longo tempo de recuperação (10 a 30 segundos) comparado à resolução temporal do estímulo químico (da ordem de milissegundos). As soluções presentes na literatura dividem-se em quatro abordagens:

- a. restrição de velocidade do veículo: adotada por Kurotsuchi, Tai e Takahashi (2016) e Castro *et al.* (2018), consistem em mitigar o atraso de leitura dos sensores ao limitar o veículo para trafegar em velocidades baixas. O segundo trabalho efetuou ensaios para caracterização da resposta do sensor utilizado (SGSX *Sensortech Limited* MiCS5524), obtendo o tempo de atraso de 0,2 segundos, tempo de pico de 1,4 segundos e termo de retorno igual a 5 segundos. Com estas condições, e

limitando a velocidade do veículo a 1 m/s, os autores estimaram o erro de detecção da fonte em 0,56 metros.

- b. aguardar tempo de sensibilização do sensor: implementada por Neumann, Hüllmann e Bartholmai (2019) e Neumann *et al.* (2020), foi considerada viável, pelos autores, uma vez que o modelo de sensor utilizado em ambos os trabalhos (*Sensirion MultiPixel gas sensors SGP30*) possui tempo de subida de 3 segundos. Desta forma, a utilização de enxames de veículos delimitando regiões de medição entre os agentes pode aumentar a área de varredura, atenuando o tempo perdido na espera para medição em cada ponto.
 - c. leitura contínua: embasado nos trabalhos de Lilienthal *et al.* (2001) e Farah e Duckett (2002), que concluem que a resposta máxima de um sensor MOX corresponde à localização aproximada da fonte do gás, se a aquisição for realizada em movimento. Este comportamento foi atribuído ao longo tempo de recuperação destes sensores. Se o sensor for submetido a dois fragmentos de gás, a resposta ao segundo estímulo ocorrerá quando o sensor ainda não se recuperou da primeira leitura, sendo uma resposta de magnitude maior do que se o sensor já estivesse plenamente recuperado. Como a densidade local do gás tende a aumentar próxima à fonte, a taxa de encontro com fragmentos de gás tende a ser maior se o robô está se movimentando. Este comportamento não foi observado quando utilizada a estratégia para-sente-vai ou voo de borboleta, que consiste em pousar o veículo em um ponto de interesse, desligar as hélices, realizar a medição para só então decolar com o veículo em direção a outro ponto de interesse, repetindo esta manobra. A leitura contínua foi a abordagem utilizada nesta tese.
 - d. implementação de técnicas numéricas: dentre as propostas de utilização de algoritmos de filtragem e extração de características da saída bruta do sensor de gás, o método proposto por Schmuker, Bahr e Huerta (2016), emerge como uma solução confiável. Seu princípio consiste em extrair características de curta escala de tempo (nomeadas *bouts*) da derivada da resposta do sensor MOX, que podem ter sido causadas pelo contato com filamentos das plumas. Os autores verificaram em ensaios que a frequência de aparecimento destes *bouts* está diretamente correlacionada com a proximidade da fonte de gás. Nesta tese será proposta a utilização de uma modificação do conceito original de *bout*.
-

1.2.3. Influência das Hélices

Por fim, a influência do movimento das hélices no fluxo de ar na vizinhança do sensor de gás consiste em um problema importante que requer especial atenção dos pesquisadores nesta área. O trabalho de Luo *et al.* (2016) denomina este problema como efeito olfatório aerodinâmico.

O trabalho de Rossi e Brunelli (2017) propôs a possibilidade de posicionar os sensores, tanto com suportes rígidos quanto móveis, afixados na parte inferior do corpo da aeronave como forma de diminuir o efeito das hélices. Entretanto esta solução se mostrou inviável pois altera significativamente a inércia e a massa da aeronave, requisitando soluções de contrapeso que excedem o *payload* do veículo. Outra solução proposta no trabalho é a utilização do veículo no modo borboleta. Embora a aplicação seja viável, esta estratégia aumenta significativamente o tempo de ensaio e esbarra na limitação de tempo de voo imposta pelo modelo de aeronave adotado neste projeto. Além disso, a vantagem da varredura tridimensional do ambiente é desperdiçada ao obrigar a aeronave pousar no solo ou sobre uma superfície para efetuar cada medição.

O trabalho de Burgués *et al.* (2019) conclui que, de fato, a distribuição de gás próxima ao drone se altera drasticamente, mas que, no entanto, ainda é possível extrair características relevantes para a localização da fonte de gás.

No estudo, os autores aferiram a detecção de gás em três diferentes posições relativas a uma fonte conhecida, 25 cm acima, 65 cm acima e 50 cm à frente, nas situações dos motores ligados e desligados. Foi verificado que a frequência de *bouts* aumentou consideravelmente nas posições acima da fonte e diminuiu na posição frontal, enquanto a amplitude diminuiu nas posições acima e não sofreu alteração na posição frontal.

1.3. Justificativa

Segundo Jing, Meng e Ishida (2021), a localização de fonte de odor é um campo interdisciplinar que envolve robótica, biologia e biônica, otimização matemática, inteligência de enxame, teoria da probabilidade, *machine learning*, teoria de controle, processamento de sinais, dentre outras. A LFO robótica é também um campo associado à engenharia, o qual se relaciona com necessidades práticas como prevenção de vazamento de gases tóxicos, monitoramento ambiental, busca por recursos naturais, entre outros.

Mais precisamente, o problema da detecção de fonte de odor em ambientes internos configura-se como um importante elemento para a melhoria da segurança do ambiente de trabalho. A integração de um sistema autônomo e inteligente capaz de detectar a fonte de vazamentos de gases aos sistemas de gerenciamento do ambiente laboral vem ao encontro do advento da Indústria 4.0.

A utilização dos veículos aéreos não tripulados traz novas possibilidades para a solução deste problema, as quais até então eram estudadas apenas em ambiente de simulação. Neste sentido, verificou-se um crescente interesse dos estudos no campo de detecção de fonte de odor utilizando nanodrones a partir do ano de 2017. A utilização de um sistema de detecção de fonte de odor através de nanoquadricópteros pode ser justificada respondendo a três perguntas:

- a. **Por que utilizar robótica móvel ao invés de uma rede de sensores fixos?** Quando comparados com os sistemas fixos de detecção de gás, a utilização de robótica móvel é mais flexível e adaptável em situações de eventos naturais, acidentes ou ataques militares (BAYAT, et al., 2017).
 - b. **Por que utilizar robôs aéreos ao invés de robôs terrestres?** Robôs aéreos podem voar em ambientes com relevou limitação de acesso por terra, inacessíveis para robôs terrestres, além de performar busca tridimensional no ar, sendo capazes de obter mais informação sobre a possível localização da fonte de odor quando comparados com veículos terrestres. Até então as pesquisas utilizando robótica móvel para esta tarefa, limitavam-se aos robôs terrestres e, portanto, em uma única cota. Os estudos considerando detecção em três dimensões eram aplicáveis apenas em ambientes subaquáticos ou simulações.
 - c. **Por que utilizar nanodrones ao invés de veículos maiores?** Os nanodrones, isto é, os veículos aéreos não tripulados com massa menor que 200g, possuem a capacidade de voar em ambientes internos e estreitos, sendo, portanto, indicados em situações específicas nas quais o uso de veículos maiores seria inviável, como por exemplo, em galpões industriais ou em situações de tragédias envolvendo buscas em prédios colapsados.
-

1.4. Objetivos

Neste trabalho será proposto um algoritmo de busca pela fonte de odor que consiste na construção de um mapa de concentração de odor, o qual proverá informação para algoritmos de aprendizagem declararem a estimativa para a posição da fonte.

No algoritmo proposto, será realizada a extração de características do sinal nomeadas como *bouts* de amplitude para, a partir da extrapolação de suas leituras, obtermos um mapa estimado de distribuição de concentração de gás. As estimativas da posição da fonte serão avaliadas a partir do emprego de um algoritmo de rede neural *perceptron* multicamadas e um algoritmo de aprendizagem de máquina baseado em *gradiente boosting*.

O desempenho do algoritmo será avaliado através de ensaios práticos com aeronaves do tipo nanoquadricóptero em um ambiente interno. O detalhamento da solução proposta neste trabalho encontra-se no Capítulo 2.

O objetivo principal será dividido nos seguintes objetivos específicos:

- análise e avaliação do hardware a ser utilizado no projeto, incluindo o modelo do veículo aéreo, do sistema de posicionamento local e do sensor químico de detecção de gás;
- embarcar o sensor na aeronave e desenvolver a interface de comunicação entre ambos;
- realização de ensaios para a caracterização da resposta do sensor de gás;
- avaliar quais dados serão extraídos das leituras do sensor de gás, que propiciem maior eficácia na localização da fonte de odor.
- desenvolvimento do algoritmo computacional que irá guiar a aeronave no mapeamento do ambiente e na declaração da posição da fonte de gás;
- planejamento dos ensaios experimentais e a avaliação dos resultados obtidos.

1.5. Organização Geral

Esta tese encontra-se dividida nos seguintes capítulos:

- **Capítulo 2 – Estado da Arte:** Apresenta uma análise do estado da arte referente aos métodos para a localização de fontes de odor, mencionando a contribuição realizada neste trabalho.
 - **Capítulo 3 – Materiais:** Aborda o primeiro objetivo específico proposto, detalhando os componentes físicos utilizados neste projeto, incluindo a aeronave *Crazyfly 2.0*, o sistema de posicionamento local, além dos sensores de gás e de temperatura e umidade.
 - **Capítulo 4 – Metodologia:** Descreve a metodologia aplicada no desenvolvimento desta tese, incluindo a caracterização da resposta do sensor de gás e os algoritmos para mapeamento e estimação da posição da fonte de odor propostos neste trabalho.
 - **Capítulo 5 – Resultados e Discussões:** Apresenta as discussões sobre os resultados obtidos nos ensaios computacionais e experimentais.
 - **Capítulo 6 – Conclusão:** Apresenta uma análise sobre o projeto desenvolvido e traz perspectivas sobre o desenvolvimento de trabalhos futuros.
 - **Referências Bibliográficas**
-

CAPÍTULO 2

ESTADO DA ARTE

Neste capítulo serão detalhados os trabalhos que apresentaram soluções, premissas ou proposições que eventualmente foram utilizadas nesta tese, bem como aqueles mais recentes cujas abordagens encontram-se no mesmo campo da taxonomia da solução aqui proposta. Os trabalhos serão subdivididos em três linhas: 1) veículos aéreos; 2) mapeamento do ambiente utilizando técnicas estatísticas e 3) algoritmos de aprendizagem.

2.1. Veículos Aéreos na Tarefa de Localização de Fonte de Odor

Embora existam trabalhos que utilizam outros tipos de aeronaves na tarefa de localização de fonte de odor, a maioria das aplicações fazem uso de aeronaves de asas rotativas como o proposto nesta tese, portanto, o levantamento foi realizado buscando os trabalhos próximos mais relevantes dentro desta categoria de veículos. Será adotada a taxonomia dos VANTs de asas rotativas tal como proposto por Brooke-Holland (2012) em que os drones utilizados nestas tarefas podem ser classificados pelo peso como minidrones (entre 5 e 2 kg), microdrones (entre 200 g e 2 kg) e nanodrones (abaixo de 200 g).

Segundo Shen, Yuan e Shan (2021), as estratégias de busca em duas dimensões, por veículos terrestres ou mesmo por aeronaves que voam em uma altura fixa, ignoram a natureza tridimensional da pluma, resultando, em alguns casos, em completa ineficácia na tarefa de busca. Este efeito é visível, sobretudo, nas situações em que o gás de interesse é mais leve que o ar.

Neste cenário, o emprego de VANTs, embora traga novos desafios, constitui-se como uma linha de investigação muito explorada na área. Provavelmente, o problema de maior

impacto dada a utilização de aeronaves na tarefa de LFO seja a influência do movimento das hélices na dispersão de gases no ambiente. Neste trabalho, este efeito será tratado também como efeito olfatório aerodinâmico (LUO *et al.*, 2016) e efeito de rastro das hélices, em tradução livre de “wake” (VILLA, 2016).

Luo *et al.* (2016) realizaram um estudo sobre a influência da dispersão de gás ocasionada utilizando o método dos vórtices como simulação, dando luz à diversas considerações sobre o impacto da utilização de aeronaves de asas rotativas nestas tarefas.

Em Eu e Yap (2018), o problema da influência do movimento das hélices em situações nas quais a fonte encontra-se acima da cota da aeronave foi abordado. Os autores observaram que o fluxo de admissão de ar faz com que mais moléculas do gás de interesse sensibilizem o sensor, já nas situações em que a fonte se encontra abaixo da cota de voo, o fluxo de saída de ar diminui a detecção do gás. Com isto, eles constaram, que a variação na cota de voo é um dos fatores mais importantes para o sucesso dos algoritmos de busca.

Visando a solução do problema do rastro gerado pelas hélices, diferentes abordagens foram propostas. A primeira consiste em afastar os sensores químicos da região de turbulência, utilizando extensores, como em Neumann, Hüllmann e Bartholmai (2019), ou carregando o sensor a uma distância suficiente, como proposto por Burgués *et al.* (2021). Esta abordagem, entretanto, é considerada inviável para um nanodrone, como o utilizado nesta tese, uma vez que o acréscimo de inércia à estrutura pode tornar o veículo incontrolável.

A segunda abordagem ao problema consiste em adoção de estratégias de voo como o voo de borboleta, que consiste em pousar o veículo por um período de tempo tal que o efeito da turbulência se disperse e os sensores sejam capazes de realizar a leitura mais acurada do sinal de concentração do gás. Esta abordagem, também encontra empecilhos para ser utilizada no *Crazyflie 2.0* devido ao reduzido tempo de voo (até 7 minutos).

A terceira abordagem consiste em identificar posições para afixação do sensor no corpo da aeronave tal que o efeito seja minimizado. Em Do, Lee e Kim (2020), o efeito das hélices foi estudado utilizando velocimetria de partículas e os autores concluíram que as melhores posições, em ordem decrescente são: no meio do drone, próximo ao centro de gravidade (CG), abaixo do CG, acima do CG e afixado no rotor. Já o trabalho de Shigaki, Fikri e Kurabayashi (2018), utilizando velocimetria por imagem de partículas, constatou que a posição ótima para posicionamento dos sensores é na parte frontal próxima aos rotores da frente do veículo. Segundo os autores, isso se deve porque esta região recebe o ar induzido diretamente pelas hélices sem, no entanto, ser a posição com maior velocidade de ar. Ainda segundo os autores,

relevando o princípio de funcionamento do sensor, que se baseia em aquecimento do transdutor, uma corrente de ar mais intensa acaba por reduzir a temperatura de operação do equipamento e com isso tende a haver uma menor sensibilização. Especificamente em nanodrones, o trabalho de Ercolani *et al.* (2020) mostrou que a posição com mais sucesso nas buscas foi aquela em que o sensor é embarcado logo abaixo do CG.

Constata-se, portanto, a existência de conclusões divergentes na literatura acerca do posicionamento ótimo do sensor no corpo do veículo. Nesta perspectiva, neste trabalho optou-se por afixar o sensor na parte superior do corpo do veículo, logo acima do centro de gravidade. Esta escolha foi tomada, sobretudo, devido à maior simplicidade de conexão com o veículo, no qual ainda estará conectada uma *tag* referente ao sistema de posicionamento local. Durante os ensaios realizados neste projeto, verificou-se que, não obstante, foi possível extrair informação útil das leituras do sensor, o que se mostrou suficiente para alcançar os objetivos propostos neste trabalho.

A quarta abordagem empregada para solucionar o efeito consiste em empregar técnicas de extração de características da resposta transitória do sinal. Este problema vem sendo enfrentado mesmo antes do uso de veículos aéreos na tarefa e, no entanto, o uso destes veículos trouxe um desafio maior neste campo. Como solução, Mishra, Dwivedi e Das (2013) utilizaram o método de *Gradient Descent with Momentum Back Propagation* (GDMBP) para classificar o sinal lido em concentrações específicas, separado pela técnica da multiplicação de inclinação média. Rehman e Bermak (2018) utilizaram um classificador de k-ésimo vizinho mais próximo para estimar a distribuição de concentração do gás em um ambiente com um *array* com 16 sensores. O trabalho de Di Lello *et al.* (2014) aplicou um modelo de chaveamento de sistemas lineares dinâmicos, cujos parâmetros eram sintonizados a partir das leituras, e assim seriam capazes de estimar a concentração no ambiente através de uma perspectiva probabilística.

Neste trabalho, será explorada a solução cuja inspiração vem do trabalho de Pyk *et al.* (2006), que realizou estudos acerca do comportamento da pluma, concluindo que a informação da frequência apresentada pelo sinal lido é capaz de representar a distância até a fonte de odor com mais precisão do que a amplitude do sinal. Esta conclusão foi posteriormente aprofundada por Schmuker, Bahr e Huerta (2016) que relacionou a distância até a fonte à um atributo do sinal chamado de *bout*, que são porções de subidas bruscas do sinal filtrado por um filtro passa-baixas. Os autores concluíram que a contagem de *bouts* relaciona-se de modo inversamente proporcional à distância até a fonte de odor. Esta perspectiva foi expandida no trabalho de Burgués e Marco (2020), em que foi proposto um método não recursivo de extração de *bouts*

que é inerentemente estável e de fácil implementação e otimização em algoritmos de busca. Os autores concluíram também que, mesmo que a distribuição de gás próxima ao drone se altere drasticamente, ainda é possível extrair características relevantes da contagem e desvio padrão dos *bouts*, relacionando estas grandezas com a distância até a fonte e o ângulo do ponto de leitura em função da reta paralela à qual o gás está sendo ventilado.

O trabalho de Shigaki, Fikri e Kurabayashi (2018), implementa uma estratégia de busca biomimética baseada no comportamento do macho adulto do bicho-da-seda. O problema do elevado tempo de resposta foi compensado através da escolha do modelo MiCS5524 e realizando filtragem da saída do sensor através de um modelo ARX desenvolvido pelos autores. Os sensores, quando expostos ao etanol, exibiram um comportamento capaz de estimar a posição relativa da fonte de odor em relação à direção de voo e com isso foram capazes de alimentar o algoritmo de busca proposto. Os autores obtiveram taxa de sucesso de até 80% em uma busca tridimensional, a depender da altura que se encontrava a fonte de gás.

O trabalho de Anderson *et al.* (2019) desenvolveu um sensor eletrobiológico, a partir da antena de uma mariposa, para contornar o problema do elevado tempo de resposta médio dos sensores de gás comerciais. O trabalho utilizou uma estratégia de busca pela fonte de odor biomimética, com uma estrutura física acoplada ao veículo para assegurar o voo na direção contrária ao vento. A utilização do sensor desenvolvido no trabalho tornou a busca mais rápida em relação aos trabalhos realizados com sensores puramente sintéticos.

Utilizando o *Crazyflie 2.0*, Castro *et al.* (2018) embarcaram um sensor SGSX MiCS5524 para implementar um algoritmo de busca ativa em um ambiente interno sem fluxo de vento. O algoritmo consiste em primeiramente explorar toda a região em uma altura fixa até que o sensor detecte um nível de concentração superior a um limiar estipulado, e uma vez detectada a pluma, a aeronave realiza movimentos em espiral em cota ascendente, sendo capaz de declarar a fonte quando o valor de concentração lido ultrapassa um outro limiar predefinido.

O trabalho de Burgués *et al.* (2019) propôs duas estratégias de mapeamento, ambas baseadas na extração de características do sinal, sendo a primeira a partir da medição instantânea e a segunda através da frequência de detecção dos *bouts*. Os autores constataram que a utilização da estratégia de rastreamento da pluma, utilizando a premissa do gradiente de gás medido pela leitura instantânea e da frequência de *bouts*, a princípio, não se mostrou eficiente, propondo, então, um algoritmo de mapeamento que é construído por um computador após os ensaios a partir das informações coletadas pelo robô.

O trabalho de Duisterhof *et al.* (2021) desenvolveu um algoritmo de busca nomeado *Sniffy Bug*, utilizando um enxame de *Crazyflies* embarcados com sensores MOX Figaro TGS8100, para localizar a fonte de odor em um ambiente estreito e sem presença de GPS. Os autores utilizam um algoritmo baseado em otimização por enxame de partículas em que os parâmetros foram otimizados por um algoritmo genético. Pela análise dos resultados, conclui-se que os parâmetros evoluídos pelo algoritmo genético superaram os parâmetros sintonizados manualmente, tanto nas simulações quanto nos ensaios com veículos reais, observando menos colisões entre os veículos (o que é recorrente no uso de algoritmos de evolução multiagentes), além de maior taxa de sucesso na declaração da fonte. Para um ambiente de 10 m x 10 m, os autores consideraram bem sucedido o algoritmo que localizasse a fonte com um erro inferior a 2 m, obtendo até 91,6% de sucesso nos ensaios práticos.

No trabalho de Ercolani *et al.* (2022), os autores compararam a eficiência de dois algoritmos de mapeamento de distribuição de gás baseados em infotaxia com um algoritmo que perfaz um passeio aleatório pelo ambiente. Os autores concluíram que métodos tradicionais de infotaxia podem focar muito mais em áreas com elevada variabilidade de gás enquanto ignoram uma região grande no ambiente, o que os tornaria menos eficientes quando utilizados nas abordagens de modelagem da pluma e mapeamento de distribuição de gás. Além disso, em comparação com simulações, foi notável que a influência aerodinâmica das hélices afeta o desempenho de métodos de exploração clássicos. Por fim, os autores observaram que a segmentação do ambiente favoreceu os métodos de infotaxia ao acrescentar um peso maior na exploração, sendo capazes de aumentar a quantidade de células exploradas, além de manter a qualidade dos mapas gerados nas regiões próximas à fonte.

2.2. Mapeamento do Ambiente Utilizando Extrapolação por Kernel Gaussiano para Detecção da Fonte de Odor

Dentre os algoritmos que utilizam a abordagem do mapeamento do ambiente como premissa para a solução do problema da LFO, os algoritmos de extrapolação por kernel modelam a pluma como um problema de estimação de densidade, sem, no entanto, sustentarem-se sobre premissas em relação ao modelo da pluma. Neste trabalho, os algoritmos que estimam o problema de densidade de probabilidade utilizando uma função de kernel gaussiano serão abordados.

O primeiro trabalho a apresentar a utilização de extrapolação por kernel gaussiano foi Lilienthal e Duckett (2004). Os autores, relevando a estratégia de mapeamento e a relativa pequena área que cada leitura do sensor representa, propuseram uma solução consistindo na extrapolação dos dados lidos por meio de uma função gaussiana ponderada para preencher o espaço de busca não explorado pelo veículo e assim otimizar a tarefa. Os autores concluíram que, nos casos de uma distribuição de gás dominada pela difusão, o valor máximo calculado pela extrapolação corresponde a uma boa aproximação da localização da fonte. Entretanto, em cenários dominados pelo fluxo de ar, em que a dispersão se dá através de plumas, a localização do máximo da função apresentou baixa acurácia. Neste cenário, o mapeamento através de um kernel gaussiano resultou em uma distribuição com elevada entropia, isto é, com estimativas da fonte espalhadas ao longo de uma forma no espaço. Assim os autores sugeriram relacionar a acurácia da estimação da função com o formato da distribuição calculada.

A tese de Vuka (2016) propõe um algoritmo de exploração que faz um mapeamento do ambiente utilizando uma função de extrapolação por kernel gaussiano a partir dos *bouts* extraídos das medições de concentração. Os autores partem da premissa, apresentada em Schmuker, Bahr e Huerta (2016), de que a contagem de *bouts* é inversamente proporcional à distância até a fonte, sendo confirmado em ensaios em um túnel de vento, entretanto, sendo verificado inconsistente pelos autores em testes realizados em um ambiente aberto. Nesta situação, os autores verificaram que a amplitude média dos *bouts* detectados é capaz de relacionar-se com a distância até a fonte e não a contagem destes. Para declaração da fonte, os autores utilizaram como estratégia a medida da variância menor a um valor limiar preestabelecido.

O trabalho de Prabowo *et al.* (2020) propôs um algoritmo que utiliza uma função de densidade de probabilidade por kernel gaussiano que, por sua vez, alimentará um algoritmo de inferência Bayesiano para estimar a posição da fonte a cada detecção de gás. Os autores propõem utilizar dados como o tempo em que a fonte está aberta e um coeficiente de força da fonte, além da concentração lida para melhor estimar sua posição. Os resultados foram obtidos a partir de ensaios em simulação e não fizeram considerações sobre a característica dos sensores, restrições cinemáticas ou interferência atmosférica dos agentes.

2.3. Algoritmos de Aprendizagem para Declaração da Fonte de Gás

O primeiro trabalho a empregar uma técnica de aprendizagem no problema de LFO foi proposto por Lilienthal e Duckett (2004). Neste algoritmo, um robô terrestre realiza um mapeamento pelo ambiente, permanecendo em cada ponto tempo suficiente para executar uma manobra de giro sobre si mesmo, de modo a obter uma leitura de concentração média ao longo do tempo. Deste modo, em cada ponto de leitura, um vetor com as informações temporais era extraído e tanto o vetor inteiro quanto características como a média e o desvio padrão foram utilizadas no treinamento da rede neural. Os autores utilizaram um algoritmo de aprendizagem de máquina do tipo máquina de vetor de suporte (SVM, do inglês *Support-Vector Machine*) para classificação dos padrões em duas categorias: próximos à fonte (distâncias menores que 50 cm) e distantes da fonte. Os autores concluíram que, embora o desempenho do classificador diminuiu em função da distância, este se mostrou mais eficiente em comparação com o classificador por limiar, abrindo caminho para esta nova abordagem para declaração da fonte de odor.

De Croon *et al.* (2013) utilizaram uma rede neural *feedforward* cujos parâmetros (pesos e constantes de tempo) foram sintonizados através de otimização evolucionária. Os autores alimentaram a RNA com as informações momentâneas sobre a concentração lida, gradiente de concentração e as direções do vento nos sentidos de x e y , e esta provia, como saída, a velocidade e orientação do robô no ambiente de trabalho. As observações do comportamento do robô em ambientes de baixa e elevada turbulência revelaram uma nova estratégia de busca direta que, pelos resultados apresentados, se mostrou mais eficiente que um algoritmo biomimético. As simulações foram realizadas em um ambiente bidimensional percorrido por um robô terrestre, portanto não tendo sido feitas considerações sobre o comportamento do fluido induzido pelas hélices. Além disso, o algoritmo apresentado, embora percorra a direção da fonte, foi executado em períodos da ordem de 900 segundos, o que é impraticável para o veículo utilizado nesta tese.

Nos trabalhos de Bilgera *et al.* (2018) e Yamamoto *et al.* (2019), foi utilizada uma rede neural de memória longa de curto prazo que é capaz de extrair características espaciais a partir de um dado sequencial, além de classificar e fazer previsões. Os autores utilizaram uma rede de sensores espalhados em um grid de 5 por 6 metros e um anemômetro para, a partir dos dados temporais medidos por eles, serem capazes de estimar a posição da fonte com uma taxa de sucesso superior a 93%, tendo considerado a ideia promissora. Uma abordagem semelhante foi utilizada no trabalho de Kim *et al.* (2019), entretanto com uma quantidade menor de sensores

de gás espalhados no limiar do terreno de uma planta industrial. Os autores compararam a utilização de uma rede neural de memória longa de curto prazo com uma RNA *feedforward* para identificação do tanque onde houve vazamento, dentre uma quantidade finita de possibilidades, observando melhor desempenho na primeira técnica (até 97% de acurácia). Embora as estratégias de utilização de uma RNA de memória longa de curto prazo provaram-se eficientes na tarefa utilizando uma rede fixa de sensores, a utilização desta estratégia em um robô móvel, entretanto, necessita de maior exploração, uma vez que as medições em cada ponto do ambiente não são feitas simultaneamente, sendo introduzido um elemento temporal entre as amostragens.

Os trabalhos de Chen, Fu e Huang (2021) e Zhao *et al.* (2022) propuseram algoritmos de aprendizagem por reforço utilizando uma *deep q-network*. No primeiro trabalho, a rede neural recebe a medição temporal da concentração de gás para alimentar um modelo de distribuição de contatos com o odor (eventos nos quais o sensor indica uma sensibilidade em resposta ao contato com uma pluma) e provê, como saída, uma sequência de ações do robô tal que maximize as recompensas estabelecidas. Os autores argumentam que a utilização de aprendizagem por reforço tende a ser mais robusta que a utilização dos algoritmos baseados em regras porque o aprendizado se dá a partir de diferentes configurações de ambientes. Os autores consideraram o resultado satisfatório, entretanto alegam que a aplicação do método pode levar a um aumento significativo do tempo que o robô leva para declarar a fonte, quando submetido a ambientes com configurações diferentes das treinadas, o que poderia inviabilizar seu uso em aeronaves com baixo tempo de execução para a tarefa. Além disso, diferentes resultados foram obtidos em diferentes simuladores quando incluída a dispersão ao longo da dimensão *z*, portanto havendo necessidade de validação experimental em ambientes tridimensionais. No trabalho de Zhao *et al.* (2022), os autores investigaram a utilização do mesmo tipo de RNA, entretanto a partir de uma abordagem de clusterização de partículas. A ideia principal foi agrupar as amostras recolhidas ao longo dos ensaios em clusters de densidade, de tal forma que a quantidade de amostras presentes em cada cluster denota a probabilidade de a fonte estar localizada em seu domínio. Deste modo, os autores conseguiram uma acurácia de 99,6%.

Em Wang e Pang (2020) e Wang, Pang e Li (2021), os autores comparam a utilização de um algoritmo de *machine learning* e dois de *deep learning* para resolver o problema. Os autores implementaram o modelo de um sistema de inferência adaptativo *neuro-fuzzy* e uma rede neural *feedforward* e outra convolucional treinados a partir dos padrões observados no comportamento de dois algoritmos de LFO, um biomimético inspirado no movimento das

mariposas e outro que utiliza inferência Bayesiana. Os autores treinaram as RNAs fornecendo as informações sobre a intensidade do vento em x e y , a leitura de concentração de odor, a posição do robô no espaço bidimensional e sua orientação. Como saída, mantendo a velocidade constante em 1 m/s, era fornecida simplesmente a orientação do robô. Os autores concluíram que a estrutura escolhida para as redes neurais é altamente influente no desempenho final. Além disso, a RNA convolucional foi apontada como a que apresentou melhor acurácia porque ela gera comandos baseados em dados anteriores do sensor, sendo, portanto, mais adequada, principalmente, para a subtarefa de rastreamento da pluma.

2.4. Conclusão

Nesta seção, uma síntese do estado da arte será realizada e as contribuições que a presente tese propõe serão destacadas a partir das soluções semelhantes encontradas na literatura para os problemas de rastro gerado pelas hélices e construção de um mapa de distribuição de concentração de gás no ambiente.

No Quadro 2.1, encontram-se as soluções para o problema do rastro gerado pelas hélices. Destaca-se que, após análises, dentre as abordagens existentes, a extração de características do sinal se mostrou a mais promissora para ser utilizada em uma solução envolvendo um nanoquadricóptero pois não mitiga sua vantagem que consiste na exploração tridimensional do ambiente e nem requer modificações físicas que porventura influencia na dinâmica e controle de voo.

No Quadro 2.2, encontram-se os trabalhos que se debruçaram sobre a abordagem de mapeamento de distribuição de odor no ambiente como solução ao problema de LFO.

Nesta tese optou-se pela abordagem do mapeamento a partir das conclusões do trabalho de Burgués *et al* (2019), em que os autores concluíram que o uso de bouts mostra-se eficiente quando empregado na abordagem do mapeamento ao invés da busca reativa.

A algoritmo de mapeamento proposto nesta tese envolve ainda o emprego de um planejador de trajetórias baseado no método dos campos potenciais modificados e cujos resultados encontra-se no artigo de De Souza *et al.* (2022), além de uma estratégia de redução do volume de busca de forma iterativa em torno das estimativas da fonte.

Quadro 2.1 – Soluções para o problema do rastro gerado pelas hélices.

Abordagem	Trabalho	Solução	Comentário
Estudo sobre o fenômeno	Luo <i>et al.</i> (2016)	Estudos sobre a influência das hélices através de simulações.	Deu luz à possibilidade de utilização de quadricópteros na tarefa.
	Eu e Yap (2018)	Observações sobre a influência da leitura conforme a altura da fonte em relação ao veículo.	Forneceram conclusões importantes sobre um fator que impacta no desempenho do algoritmo.
Estratégias de voo	Rossi e Brunelli (2017)	Emprego do voo de borboleta.	Mitiga uma das principais vantagens que é a exploração tridimensional.
Afastar o sensor do efeito de rastro gerado pela pluma	Neumann, Hüllmann e Bartholmai (2019)	Utilizar extensores para afastar o sensor da região de influência das hélices.	Impraticável para um nanoquadricóptero devido ao acréscimo de momento de inércia.
	Burgués <i>et al.</i> (2021)	Pendurar o sensor no corpo da aeronave a uma altura suficiente para diminuir o efeito das hélices.	Impraticável para um nanoquadricóptero devido ao acréscimo de peso.
Estudo da posição ótima para os sensores no corpo da aeronave	Do, Lee e Kim (2020)	Concluíram que a melhor posição do sensor é no meio do veículo.	Resultados aparentemente contraditórios, embora as condições de cada ensaio foram mantidas sob controle e ressalvas foram feitas para voos em condições não controladas.
	Ercolani (2020)	Concluíram que a melhor posição para o sensor é na parte inferior do veículo	Neste trabalho, relevando a facilidade de construção, optou-se por utilizar o sensor na parte superior do corpo do veículo.
	Shigaki, Fikri e Kurabayashi (2018)	Concluíram que posicionar o sensor logo abaixo das hélices contribui para sua sensibilização.	
Extração de características do sinal de saída do sensor	Mishra, Dwivedi e Das (2013)	Combinaram os métodos GDMBP e ASM para classificar padrões do sinal do sensor.	A metodologia proposta busca separar diferentes tipos de gases, não necessariamente relacionar a leitura com a distância até a fonte.
	Pyk <i>et al.</i> (2006)	Relacionou a frequência do sinal de saída do sensor com a proximidade até a fonte.	Deram luz ao desenvolvimento do conceito de <i>bout</i> , que foi aprimorado neste projeto.
	Schmuker, Bahr e Huerta (2016)	Relacionaram a contagem de surtos (<i>bouts</i>) do sinal à proximidade da fonte.	Propuseram o conceito de <i>bout</i> , aprimorado nesta tese.
	Burgués e Marco (2020)	Propuseram uma metodologia de filtragem e extração de <i>bouts</i> .	Melhoraram a eficiência dos métodos de busca utilizando os <i>bouts</i> como indicadores de concentração de gás.
	Vuka (2016)	Observaram que a amplitude média dos <i>bouts</i> relaciona-se com a distância até a fonte.	A conclusão que relaciona a amplitude dos <i>bouts</i> com a distância à fonte foi generalizada nesta tese.
	Esta tese	A partir das observações de Vuka (2016) e do conceito de <i>bout</i> refinado por Burgués e Marco (2020), nesta tese será proposto o conceito do <i>bout</i> de amplitude, atribuindo um peso à cada <i>bout</i> lido.	Foi verificado que a informação sobre a média dos <i>bouts</i> de amplitude é capaz de fornecer estimativas confiáveis para construção de um mapa de distribuição de odor.

Fonte: Elaborado pelo autor.

Quadro 2.2 – Abordagem do mapeamento como solução ao problema da localização da fonte de odor.

Abordagem	Trabalho	Solução	Comentário
Estudos comparativos	Burgués <i>et al.</i> (2019)	Construção de um mapa de odor utilizando os bouts como referência para a estimativa de concentração de odor.	Os autores compararam duas abordagens de mapeamento e concluíram que o uso dos bouts é mais efetivo na abordagem de mapeamento do que de rastreamento reativo da pluma.
	Ercolani, <i>et al.</i> (2022)	Estudo comparativo entre duas estratégias de mapeamento: baseado em infotaxia e caminho aleatório.	Algoritmos de infotaxia acabam priorizando regiões com maior concentração de gás em detrimento de maior exploração do ambiente, o que pode não os torna-los ideais em estratégias de mapeamento.
Extrapolção por kernel gaussiano	Lilienthal e Duckett (2004)	Utilizaram extrapolação por kernel gaussiano na abordagem de mapeamento.	O máximo valor calculado pela função de extrapolação é uma boa aproximação da fonte em ambientes dominados pela difusão, entretanto, não muito eficiente em ambientes com dispersão turbulenta.
	Esta tese	Aprimora o método utilizado em Lilienthal e Duckett (2004) ao acrescentar um algoritmo inteligente para contornar o problema da dispersão turbulenta induzida pelas hélices.	O emprego de algoritmos de inteligência artificial se mostrou promissor para estimar a posição da fonte a partir do mapa gerado por uma extrapolação por kernel gaussiano.

Fonte: Elaborado pelo autor.

CAPÍTULO 3

MATERIAIS

Considerando o objetivo do trabalho que é utilizar a abordagem do mapeamento de distribuição de gás tridimensional, como solução ao problema de localização de fonte de odor, a escolha do veículo aéreo obedeceu a alguns requisitos. O primeiro deles consiste na demanda de que o veículo seja pequeno e leve, dada a necessidade de exploração de ambientes internos e estreitos. Além disso, como o foco do trabalho não é o desenvolvimento de uma aeronave, optou-se por uma plataforma comercial *open-source*. O *Crazyflie 2.0* atende os critérios estabelecidos, e ainda oferece um hardware capaz de embarcar sensores e atuadores de diferentes tipos, provê um *framework* para a integração de novos equipamentos com a aeronave, além de contar com um sistema de posicionamento local.

A escolha do sensor químico de detecção de gás obedeceu primariamente à necessidade de obter os menores tempos de resposta e recuperação possíveis, além de serem compactos. De acordo com a literatura pesquisada, os sensores MOX são um dos mais utilizados em aplicações robóticas devido ao tamanho reduzido, baixo custo e elevada sensibilidade, além de apresentarem uma resposta mais rápida aos estímulos. Dentre as desvantagens é possível apontar que eles necessitam de um período de inicialização elevado (24 horas) para atingirem um nível de equilíbrio com a atmosfera local, para então fornecerem uma saída acurada e estável (PETERSON *et al.*, 2017).

Além disso, os sensores MOX apresentam um deslocamento no sinal, na forma de um erro permanente, que limita sua vida útil em aplicações de longa duração, isto é, aplicações em que o sensor opera por mais de 12 horas sem interrupção. Este deslocamento é uma característica própria dos sensores baseados em óxido de metal e consiste na variação gradual e imprevisível da resposta do sinal ao longo do tempo quando o sensor permanece exposto às mesmas condições (DENNLER *et al.*, 2022).

Segundo Maag, Zhou e Thiele (2018), isto ocorre devido ao envelhecimento do sensor que resulta em uma diminuição de sua sensibilidade. Fatores ambientais como temperatura e umidade também causam erros temporários nas leituras do sensor, os quais podem ser mitigados através de técnicas de calibração. Outra característica desta categoria de sensores é a baixa seletividade, isto é, sua elevada sensibilidade a uma vasta gama de elementos químicos, sendo pouco capaz de separá-los. Outra desvantagem é o elevado tempo de recuperação, de tal forma que Burgués *et al.* (2019) atribuíram ao sensor a característica de um filtro passa-baixas, de forma que suas medições são influenciadas por detecções anteriores.

Para este projeto foi selecionado o sensor de gás modelo MultiPixel SGP30, da fabricante *Sensirion* por ser comercialmente acessível, possuir tempo de resposta menor que três segundos e possuir área inferior a 4 cm², atendendo, portanto, aos requisitos de custo, dinâmica de resposta e dimensão para o presente projeto. Como solução ao deslocamento do sinal, ele oferece a possibilidade de estabelecer *baselines* para as medições, as quais podem também ser utilizadas para ajustar a sensibilidade da resposta a diversos cenários de testes. A definição de *baseline* e a explicação de seu comportamento encontra-se disponível no capítulo 4. Os problemas de equilíbrio com a atmosfera local e o elevado tempo de recuperação podem ser negligenciados, devido ao tempo de ensaio reduzido (não mais que cinco minutos de funcionamento contínuo) e à estratégia de utilização de características da fase transitória do sinal, dispensando a necessidade de aguardar a resposta em regime permanente.

Em relação à sensibilidade devido a temperatura e a umidade, estas variáveis foram monitoradas ao longo dos ensaios por um sensor DHT11, garantindo que a operação ocorresse dentro dos valores recomendados pelo fabricante, isto é, temperatura entre 20° C e 30° C e umidade entre 40% e 80%.

3.1. *Crazyflie 2.0*

O modelo *Crazyflie 2.0*, fabricado pela empresa *Bitcraze*, Figura 3.1, foi utilizado neste trabalho por possuir, dentre outras vantagens, custo reduzido, código aberto, suporte dos fabricantes e dimensões reduzidas. Ademais, o fabricante disponibiliza um sistema de posicionamento local que contorna um dos principais desafios das pesquisas nesta área, referente à estimação da posição da aeronave no espaço. Visto que a proposta desta tese não é desenvolver uma aeronave própria, esta plataforma de desenvolvimento se mostrou conveniente.

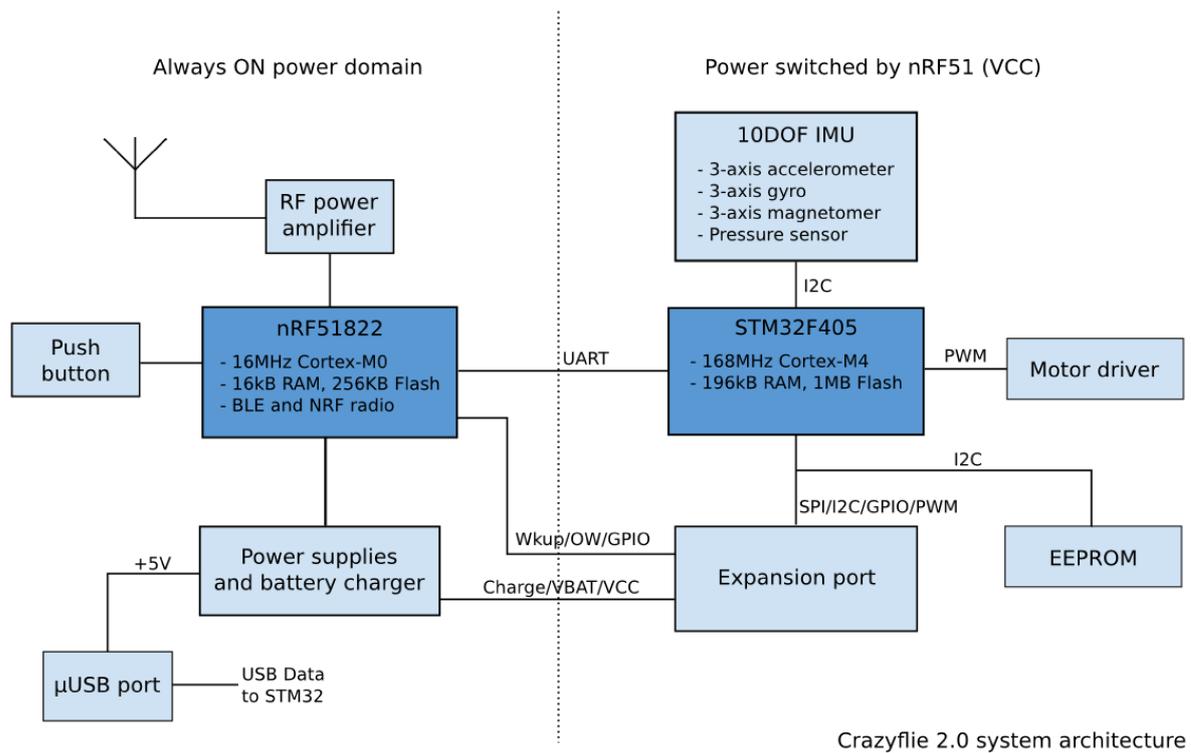
Figura 3.1 – Quadricóptero *Crazyflie 2.0*.



Fonte: Extraído de BITCRAZE (2020a).

Na sequência, será discutida a arquitetura do hardware do veículo, detalhando as especificações mais relevantes para o trabalho.

Figura 3.2 – Arquitetura do sistema do *Crazyflie 2.0*.



Fonte: Extraído de BITCRAZE (2020b).

3.1.1. Microcontroladores

O *Crazyflie 2.0* é equipado com dois microcontroladores, sendo o primeiro, modelo ARM Cortex-M4 (STM32F405) com 196 kB de memória RAM, 1 MB de memória flash e *clock* de 138 MHz, com interface com os sensores, motores e memória EEPROM, responsável pela aplicação principal e o segundo, um ARM Cortex-M0 (nRF51822) com 16 kB de memória RAM, 256 kB de memória flash e *clock* de 16 MHz, encarregado de gerenciar a bateria e a comunicação via rádio. Embora o veículo seja equipado com uma interface Bluetooth, foi verificado que a utilização da interface via rádio oferece melhor desempenho (LANDRY, 2015).

3.1.2. Unidade de Medição Inercial

A Unidade de Medição Inercial (IMU) embarcada no *Crazyflie 2.0* corresponde ao modelo MPU-9250 com 10 graus de liberdade (DoF), sendo um acelerômetro, um magnetômetro e um giroscópio (cada um com sensibilidade nos três eixos), além de um barômetro (modelo LPS25H) que auxilia na estimação da altitude.

A IMU alimenta o sistema de estimação baseado em um Filtro de Kalman Estendido (EKF), com as variáveis auferidas em relação ao sistema de coordenadas fixo ao corpo.

3.1.3. Motores e Hélices

Os quadricópteros possuem quatro conjuntos atuadores compostos por um motor acoplado a uma hélice. Os motores utilizados no *Crazyflie 2.0* são do tipo corrente contínua escovados sem núcleo que alcançam rotação máxima de 25000 rpm.

Embora a maioria dos modelos de quadricópteros utiliza motores sem escova alimentados por um circuito eletrônico para regular suas velocidades de forma precisa, os motores do *Crazyflie 2.0*, além de possuírem escovas, são alimentados por uma fonte de potência não regulada. Com isso, velocidades maiores, que requerem maior torque para quebrar a resistência do ar e, conseqüentemente, maior corrente, tendem a drenar mais carga da bateria, diminuindo sua tensão e, conseqüentemente, a autonomia de voo. Este efeito é compensado via software (LANDRY, 2015).

Apesar desta desvantagem, o motor sem núcleo escovado possui rápida resposta dinâmica e massa pequena, o que provavelmente foi considerado na sua escolha pelos fabricantes.

As hélices são fabricadas em plástico com 45 mm de diâmetro. Como os motores do veículo rotacionam em sentidos opostos, as hélices são fabricadas em dois modelos, e devem ser corretamente posicionadas nos motores que giram no sentido horário (CW) e anti-horário (CCW). Neste trabalho, para efeito de simplificação do modelo, é assumido que as forças de empuxo e arrasto produzidas pela interação do ar com a hélice são funções do quadrado de sua velocidade de rotação.

3.1.4. Bateria

A alimentação do veículo é provida por uma bateria LiPo de 3,7 V (250 mAh), o que propicia energia para aproximadamente 5 minutos de voo contínuo (BITCRAZE, 2020a). Dada a condição de funcionamento dos motores, a tensão da bateria necessita ser regulada pelo microcontrolador auxiliar, de modo a minimizar deterioração do desempenho dos atuadores.

3.1.5. Comunicação

A comunicação entre os veículos e o computador de mesa se dá através da interface de rádio. O *Crazyflie 2.0* é equipado com um amplificador de rádio de 20 dBm, testado para distâncias até 1 km com perda tolerável de sinal (BITCRAZE, 2020a).

Já o computador de mesa opera conectado via USB a um *dongle* de rádio disponibilizado pelo fabricante. Este *dongle* é baseado no Semicondutor nRF24LU1+ SoC e opera à 2.4 GHz. A taxa de transmissão de dados se dá em 250 Kbps, 1Mbps ou 2 Mbps, e possui alcance testado de até 80 m operando em 250 Kbps.

3.1.6. Parâmetros físicos

Os parâmetros físicos do *Crazyflie 2.0* foram determinados através de ensaios realizados pelo grupo de pesquisa no qual este trabalho está inserido e então comparados com os parâmetros disponíveis na literatura, Tabela 3.1. A metodologia utilizada encontra-se detalhada nos trabalhos COURY *et al.* (2019) e LIMA (2019).

Tabela 3.1 – Parâmetros físicos do *Crazyflie 2.0*.

Parâmetros	Unidades	Ensaios	Literatura
Massa (m)	kg	0,0282	0,0284
Distância entre o centro de massa e os rotores (l)	m	0,0461	0,0467
Momento de inércia ao redor do eixo x (I_{xx})	kgm^2	$1,473 \cdot 10^{-5}$	$1,657 \cdot 10^{-5}$
Momento de inércia ao redor do eixo y (I_{yy})	kgm^2	$1,479 \cdot 10^{-5}$	$1,665 \cdot 10^{-5}$
Momento de inércia ao redor do eixo z (I_{zz})	kgm^2	$2,847 \cdot 10^{-5}$	$2,926 \cdot 10^{-5}$
Coefficiente de arrasto dos motores (d)	$\frac{kgm^2}{rad^2}$	$1,217 \cdot 10^{-10}$	$1,688 \cdot 10^{-10}$
Coefficiente de empuxo dos rotores (b)	$\frac{kgm^2}{rad^2}$	$2,364 \cdot 10^{-8}$	$2,220 \cdot 10^{-8}$

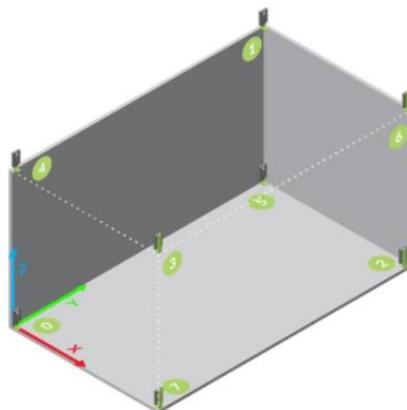
Fonte: Extraído de LIMA (2019).

3.2. Sistema de Posicionamento

O sistema de posicionamento local (*Loco Positioning System*) se baseia no módulo Decawave DWM1000, que é um transdutor em ultra banda larga operando entre 3.2 GHz e 7 GHz com largura de banda de canal de 500 MHz.

O sistema consiste em uma *tag*, conectada diretamente ao *Crazyflie 2.0* através de suas portas de expansão e um conjunto de oito nós, ou âncoras, posicionados no ambiente de ensaio, conforme disposto na Figura 3.3, por meio de suportes que foram confeccionados em impressora 3D através de projetos disponibilizados pelo próprio fabricante.

Figura 3.3 – Posicionamento dos nós no ambiente.



Fonte: Extraído de LIMA (2019).

O sistema de posicionamento implementa três diferentes modos de posicionamento: *Two Way Ranging* (TWR), *Time Difference of Arrival 2* (TDoA 2) and *Time Difference of Arrival 3* (TDoA 3).

O primeiro modo funciona com a *tag* enviando, sequencialmente, mensagens às âncoras. Em função do tempo de atraso da resposta de cada âncora, a distância até cada uma delas é calculada, sendo possível, deste modo, estimar a posição tridimensional do veículo. Este modo permite operar com seis âncoras, entretanto é capaz de estimar a posição de uma única *tag* em cada ensaio, o que inviabiliza a operação com enxames (BITCRAZE, 2020b).

Os modos TDoA 2 e TDoA 3 operam de modo semelhante, em que as âncoras enviam, continuamente, pacotes de sincronização às *tags*. Estas, através da estimativa do tempo de atraso de chegada dos pacotes de cada âncora, é capaz de estimar a distância até cada nó, e assim estimar sua posição no espaço de trabalho. A diferença entre ambos os modos reside no fato de que no TDoA 2 os pacotes são enviados em intervalos fixos e no TDoA 3 o envio dos pacotes é randomizado, o que o torna ligeiramente mais ruidoso que os outros dois modos. Como no TDoA2 e no TDoA3 as *tags* operam de forma passiva, é possível incluir um número ilimitado de aeronaves voando simultaneamente nos ensaios (BITCRAZE, 2020b).

Assim, de acordo com o fabricante, a acurácia da estimação de posição é de ± 10 cm, a depender da configuração do ambiente e do modo de funcionamento utilizado. Verifica-se que, em ambientes maiores, o erro de estimação tende a ser maior. Além disso, através dos ensaios realizados nesta tese, verificou-se que a estimação apresentou maior erro e ruído na estimação da posição na coordenada Z em comparação com os demais eixos coordenados. Neste trabalho optou-se pela utilização do modo TDoA 2, por permitir voo em enxame e apresentar melhor desempenho em relação ao TDoA 3.

Ressalta-se que, independentemente do modo de operação, a estimação da posição é realizada na própria *tag*, evitando a necessidade de um sistema externo, como um computador de mesa. Os dados fornecidos pelo *Loco Positioning System* alimentam o estimador baseado em um Filtro de Kalman Expandido, juntamente com os dados oriundos da IMU.

3.3. Sensor de Temperatura e Umidade

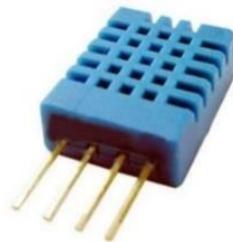
O sensor de temperatura e umidade utilizado neste projeto, o modelo DHT11, apresentado na Figura 3.4, foi escolhido pela simplicidade de comunicação e baixo custo, além de operar nas condições ambientais normalmente observadas na região, entre 20 e 90 % de

umidade relativa do ar e de 0° C a 50° C de temperatura. Este modelo possui acurácia de medição de 5% para umidade relativa e 2° C para temperatura, e resolução de 1 % e 1° C, valores os quais foram considerados suficientes para esta aplicação.

Houve a necessidade de monitoramento da temperatura e umidade durante os ensaios, devido ao fato de estas variáveis ambientais interferirem tanto no comportamento de dispersão do etanol na fase gasosa, quanto no comportamento do sensor de qualidade do ar SGP30, detalhado a seguir.

A aquisição de dados do sensor DHT11 foi implementada através de uma placa Arduino Mega 2560 conectada a um computador de mesa. As aplicações desenvolvidas em Python, incluindo uma interface gráfica de usuário desenvolvida, comunicam-se com o Arduino, recebendo os sinais de temperatura e umidade a cada segundo e os registra juntamente aos dados recebidos pelo Crazyflie durante os ensaios.

Figura 3.4 – Sensor de temperatura e umidade DHT11.



Fonte: Extraído de DHT11 (2021).

3.4. Sensor de Detecção de Gás

Para este projeto foi utilizado o sensor de gás modelo SGP30 da fabricante *Sensirion*. Este modelo foi escolhido primariamente porque possui um bom tempo de resposta (1 segundo), além de prover quatro diferentes sinais de saída e possibilidade de compensação de dois destes sinais de forma manual ou automática. Suas dimensões (2,45 mm × 2,45 mm × 0,9 mm) e peso (< 1g) reduzidos também foram preponderantes na escolha, considerando sua aplicação de forma embarcada em uma aeronave com baixo *payload*.

Os quatro sinais providos pelo sensor são: as leituras cruas do nível de hidrogênio (H₂) e etanol, e os sinais processados de total de componentes voláteis orgânicos (TVOC) e de equivalente de dióxido de carbono (CO₂eq.).

Cada sinal, composto por 16 bits, é enviado pelo sensor ao quadricóptero através de uma interface I2C. As especificações dos sinais encontram-se na Tabela 3.2, com valores medidos em parte por milhão (ppm) ou parte por bilhão (ppb). Considerando que a medição de TVOC ocorre na faixa de partes por bilhão, espera-se que este sinal se apresente mais sensível para detecção em relação ao equivalente de CO₂ que é medido em partes por milhão. A escolha sobre qual destes sinais será utilizado encontra-se detalhada no Capítulo 4 – Metodologia.

Tabela 3.2 – Especificações dos sinais medidos e processados do sensor SGP30.

Parâmetro	Sinal	Valores
Alcance de medição	Etanol cru	0 ppm a 1000 ppm
	H ₂ cru	0 ppm a 1000 ppm
Acurácia	Etanol cru	15% do valor medido
	H ₂ cru	10% do valor medido
Desvio de longo prazo	Etanol cru	1,3% do valor medido
	H ₂ cru	1,3% do valor medido
Resolução	Etanol cru	1,3% do valor medido
	H ₂ cru	1,3% do valor medido
Frequência de amostragem	Etanol cru	Até 40 Hz
	H ₂ cru	Até 40 Hz
Alcance da saída	TVOC	0 ppb a 60000 ppb
	CO ₂ eq.	400 ppm a 60000 ppm
Resolução	TVOC (0 ppb a 2008 ppb)	1 ppb
	TVOC (2008 ppb a 11110 ppb)	6 ppb
	TVOC (11110 ppb a 60000 ppb)	32 ppb
	CO ₂ eq. (400 ppm a 1479 ppb)	1 ppm
	CO ₂ eq. (1479 ppm a 5144 ppb)	3 ppm
	CO ₂ eq. (5144 ppm a 17597 ppb)	9 ppm
Frequência de amostragem	CO ₂ eq. (17597 ppm a 60000 ppb)	31 ppm
	TVOC	1 Hz
	CO ₂ eq.	1 Hz

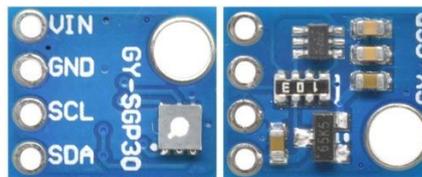
Fonte: Adaptado de SGP30 (2021).

Este sensor foi originalmente projetado para realização de leitura da qualidade do ar, sendo programado para funcionar de forma contínua durante um período prolongado. Considerando a deterioração física da acurácia das medições, que ocorre de forma natural para os sensores baseados em óxidos de metais, este modelo utiliza um algoritmo de compensação embarcada, o qual, através do ajuste automático e periódico dos valores de *baselines* dos sinais de TVOC e CO₂ equivalente, é capaz de corrigir o problema acima mencionado. Esta regulação é observada quando o mesmo se encontra em funcionamento por um período superior a uma hora (SGP30, 2021).

Considerando que os ensaios utilizando a aeronave em voo duram não mais que cinco minutos, o comportamento de regulação automática pode ser ignorado. Ao invés disso, a possibilidade de alterarmos os valores dos *baselines* pôde ser oportunamente explorada para ajustar a sensibilidade do sensor de forma manual. Esta característica permitiu analisar o comportamento dos sinais para diferentes valores de *baselines* após exposição ao gás etanol e, desta forma, escolher um valor adequado para que os sinais de TVOC e CO₂ equivalente pudessem exibir um comportamento adequado para que fosse possível a extração de informações úteis para a finalidade proposta neste trabalho. Os detalhes dos ensaios e da estratégia utilizada para tal encontram-se no capítulo 4.

Neste projeto, foi utilizado um circuito integrado semelhante ao presente na Figura 3.5.

Figura 3.5 – Placa contendo o sensor SGP30.



Fonte: Elaborado pelo autor.

CAPÍTULO 4

METODOLOGIA

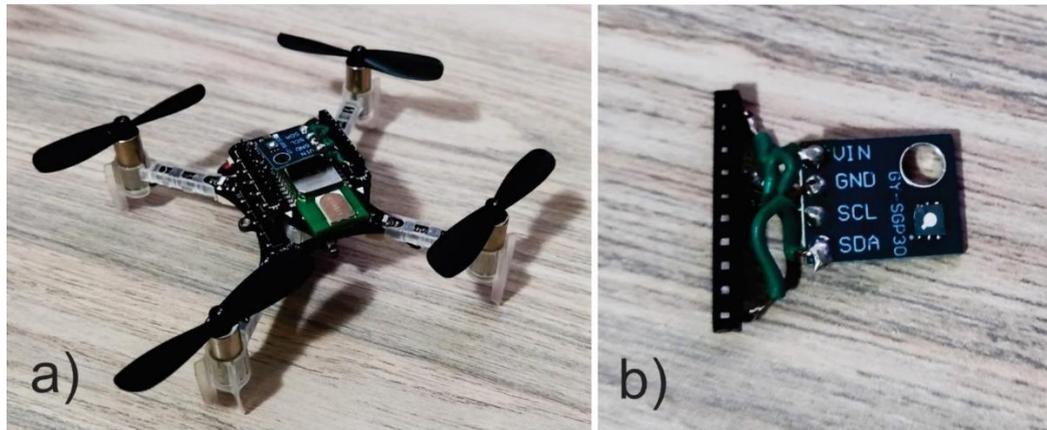
Neste capítulo, a metodologia deste trabalho será detalhada, relevando as etapas propostas na seção de objetivos presente no Capítulo 1. A primeira etapa do projeto, que consiste na escolha dos materiais a serem utilizados na pesquisa, encontra-se discriminada no Capítulo 3.

4.1. Interface de Comunicação com o Sensor de Gás

O sensor SGP30 necessita de uma alimentação com corrente de 48,8 mA e tensão entre 1,62 V e 1,98 V, suportando valores entre -0,3 V e 2,16 V, compatível com a alimentação provida pelo *Crazyflie*. A comunicação ocorre através de uma interface I2C em paralelo com a *tag* do sistema de posicionamento local, não havendo, portanto, a necessidade de inserção de resistores de *pull-up*. O sensor de gás, embarcado na aeronave juntamente com a *tag* do sistema de posicionamento, pode ser visualizado na Figura 4.1a. A Figura 4.1b apresenta o sensor conectado ao terminal de ligação.

Para estabelecer a comunicação do sensor com o *Crazyflie*, foram realizadas alterações no firmware do veículo. Foi utilizado o *framework* disponibilizado pelo fabricante e o *script* foi projetado conforme as instruções de comunicação apresentadas no *datasheet* do sensor. O código foi desenvolvido para que o sensor retorne as quatro medições disponíveis (TVOC, CO₂eq., H₂ cru e Etanol cru) sob a forma de *logs* em uma frequência de 1 Hz. Além disso, foi implementada a possibilidade de alteração dos valores de *baseline* do TVOC e CO₂ equivalente. O fluxograma do algoritmo empregado encontra-se na Figura 4.2.

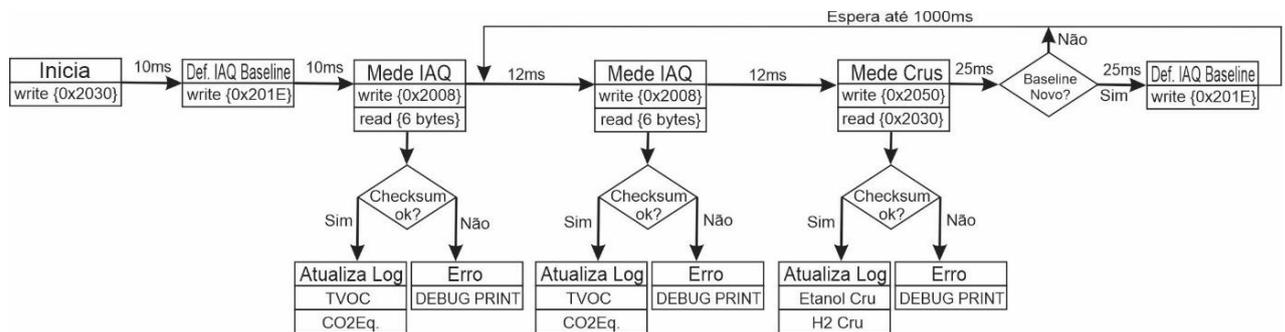
Figura 4.1 – a) *Crazyflie* com a *tag* do sistema de posicionamento e o sensor de gás; b) conexão do sensor ao terminal de ligação.



Fonte: Elaborado pelo autor.

A comunicação entre o sensor e o *Crazyflie* é inicializada, de acordo com as instruções presentes em SGP30 (2021), através do envio dos comandos de inicialização e medição de qualidade do ar. Entre estes dois comandos, a *baseline* é definida de modo a se garantir os valores definidos pelo operador. A comunicação com o sensor ocorre através do envio de comandos de 16 bits, seguidos por um *checksum* de 3 bits. O processador embarcado no veículo, que ocupa o papel de mestre na comunicação com o sensor (escravo), aguarda o tempo necessário para que a medição seja realizada pelo sensor, isto é, 12 ms para a medição do índice de qualidade do ar (IAQ) ou 25 ms para a medição dos dados crus. Após os respectivos tempos de espera, o sensor, envia a resposta ao mestre, que consiste em um dado de 6 *bytes*. O primeiro e o segundo *bytes* correspondem à informação de CO₂eq., ou H₂ cru, já o terceiro byte corresponde ao *checksum*. O quarto e quinto *bytes* representam o TVOC ou Etanol cru, e por fim, o sexto *byte* é um novo *checksum*. Por fim, o código verifica se as *baselines* foram alteradas por meio da interface gráfica de usuário e, em caso positivo, realiza a escrita dos novos valores no firmware do sensor. Após este procedimento, o código aguardará até que se tenha passado 1 segundo desde o início do laço para então reiniciá-lo, em conformidade com as instruções do fabricante.

Figura 4.2 – Fluxograma do firmware desenvolvido.



Fonte: Elaborado pelo autor.

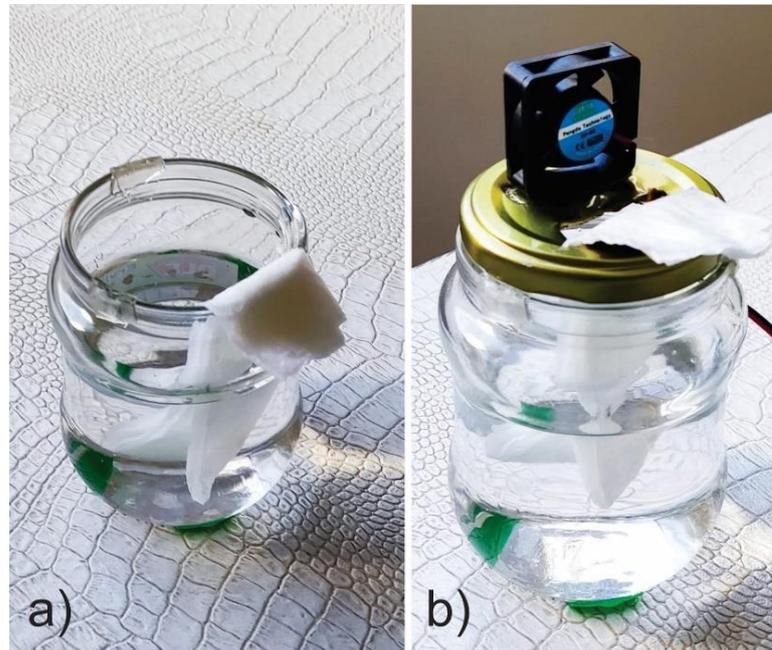
4.2. Planejamento dos Ensaios

O gás a ser detectado durante os ensaios é oriundo da evaporação do etanol líquido a 70% de concentração. Este composto foi escolhido por ser de fácil obtenção, relativamente seguro, isto é, inflamável quando em uma concentração entre 3,3% e 19% (FISPQ - ETANOL ANIDRO COMBUSTÍVEL EAC, 2019) e possuir boa evaporação em condições ambiente.

Com o objetivo de analisar o comportamento do sensor foram propostos testes em diferentes condições. Os ensaios foram conduzidos em duas situações de distribuição de gás, prevalecendo a dispersão e a turbulência. A primeira condição foi satisfeita condicionando o etanol em um recipiente com forma aproximada a um cilindro com 11 cm de altura e 6 cm de diâmetro e um papel toalha com 12 cm de comprimento e 4 cm de largura em contato com o etanol, visando aumentar a evaporação, conforme a Figura 4.3a. A distribuição dominada pela turbulência tem por objetivo simular a situação de vazamento de gás sob pressão, e foi obtida acoplado uma ventoinha (*cooler*) de microcomputador de uma polegada de diâmetro, conforme a Figura 4.3b. Em todos os testes de análise do sensor, convencionou-se que a ventoinha estivesse fixamente direcionada no sentido positivo do eixo y.

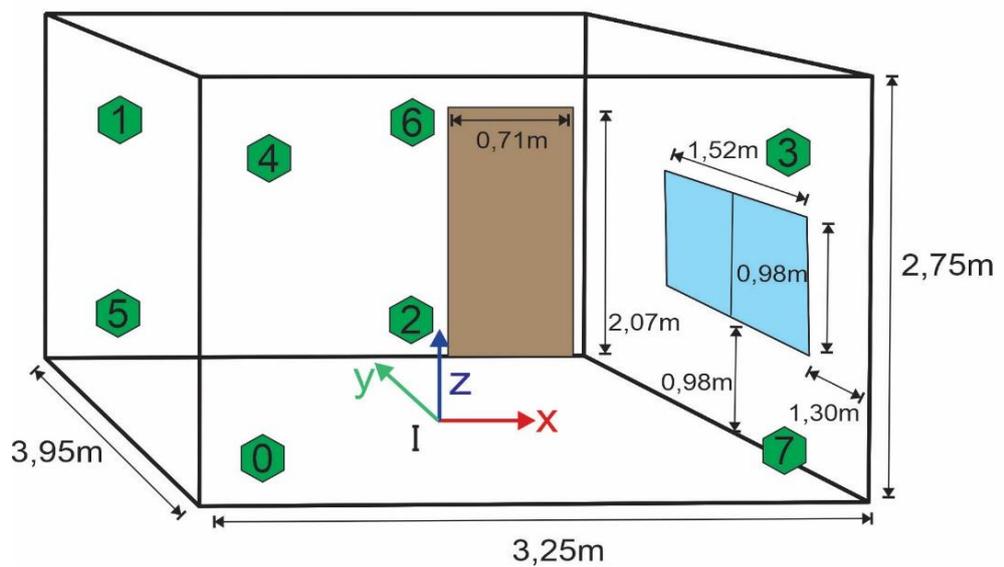
O ambiente em que os ensaios foram conduzidos possui dimensões de 3,25 m ao longo do eixo X, 3,95 m no eixo Y e 2,75 m de altura, sendo úteis 2,30 m em X, 3,5 m em Y e 1,80 m de altura, resguardando uma distância de segurança para evitar choque com as paredes, conforme apresentado na Figura 4.4.

Figura 4.3 – a) Dispositivo para distribuição do gás com predomínio da dispersão; b) dispositivo para distribuição com predomínio de turbulência.



Fonte: Elaborado pelo autor.

Figura 4.4 – Configuração do espaço de trabalho.



Fonte: Elaborado pelo autor.

As posições de cada âncora do sistema de posicionamento local, indicadas na figura pelos respectivos números nos hexágonos verdes, encontram-se na Tabela 4.1, tendo os valores referidos à origem do sistema de coordenadas inercial (I), localizada no ponto central da sala em $Z = 0$. Ressalta-se que as referências das âncoras foram subtraídas em 30 cm no eixo Z para a correção de um erro fixo apresentado pelo sistema de posicionamento. Além disso, evitou-se utilizar a aeronave em alturas inferiores a 50 cm, devido ao erro de estimação da altura que emerge dos múltiplos percursos do sinal trocado entre o veículo e as âncoras, quando este encontra-se perto do chão.

Com o objetivo de reduzir o represamento do gás no ambiente e assim evitar, além de acidentes, que o tempo que a fonte se encontra em atividade influencie nas leituras, a janela e a porta presentes no ambiente permaneceram abertas durante os ensaios e, entre cada ensaio, um ventilador foi utilizado para dispersar os gases acumulados.

Tabela 4.1 – Posição das âncoras no espaço de trabalho.

Âncora	X (m)	Y (m)	Z (m)
0	-1,47	-1,83	-0,30
1	-1,47	1,83	1,83
2	0,87	1,83	-0,30
3	1,47	-1,83	1,83
4	-1,47	-1,83	1,83
5	-1,47	1,83	-0,30
6	0,87	1,83	1,83
7	1,47	-1,83	-0,30

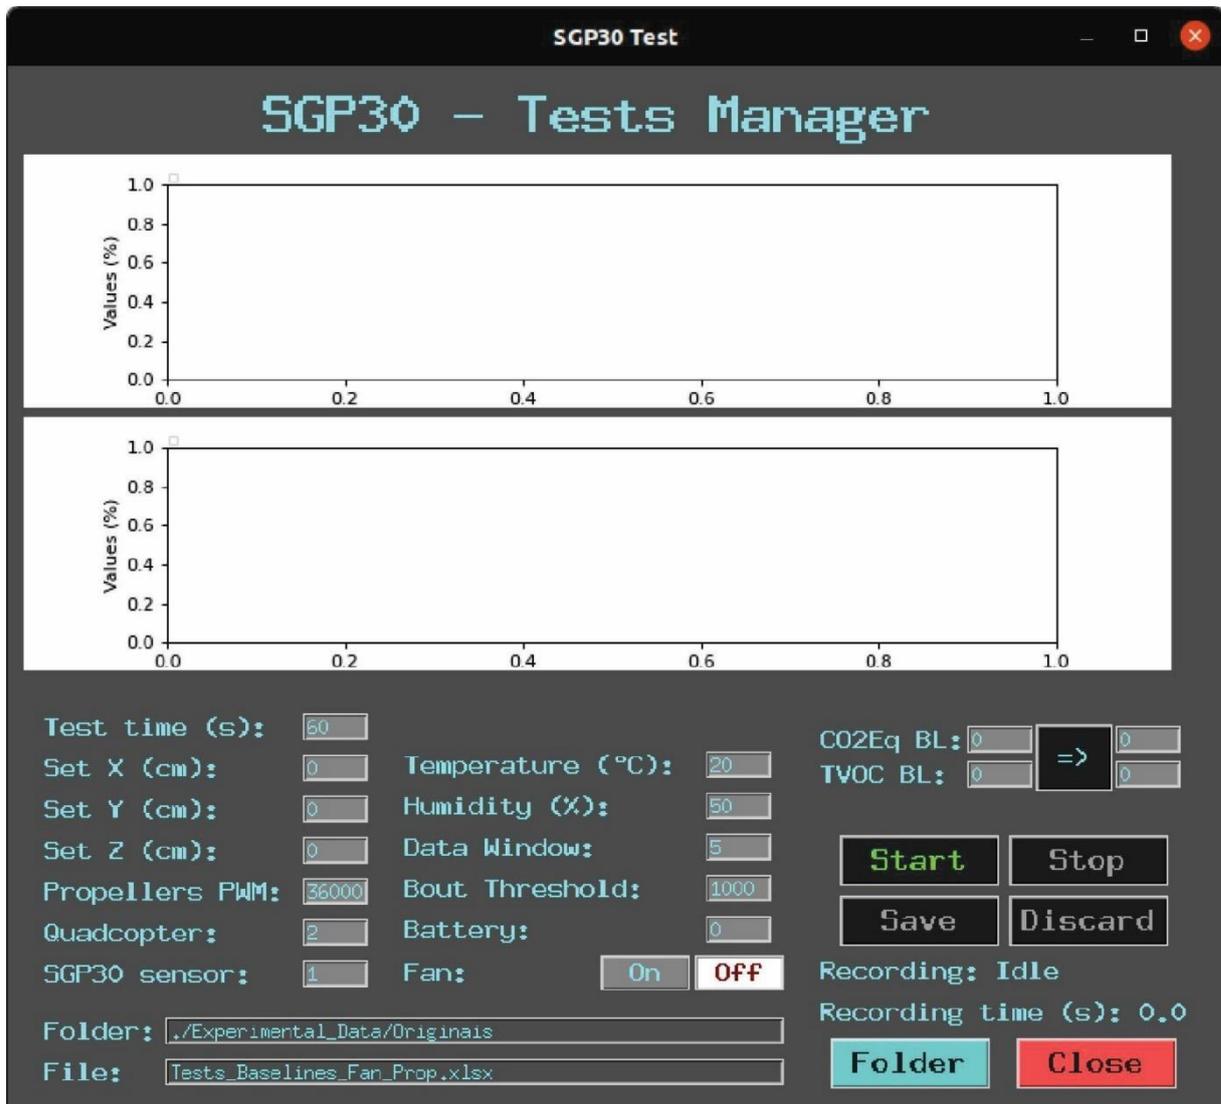
Fonte: Elaborado pelo autor.

Para o gerenciamento dos ensaios e dos dados gerados, foi desenvolvido uma interface gráfica de usuário em Python, tal como disponível na Figura 4.5.

Através desta interface, o operador visualiza, no gráfico na parte superior da tela, os valores temporais dos sinais de CO_2 equivalente e TVOC, além dos valores de *baselines* para estes sinais. No gráfico imediatamente abaixo, são plotados os valores da média e desvio padrão dos índices de *bouts* de amplitude, a serem detalhados adiante.

Na parte inferior da tela, encontram-se os parâmetros de ajustes do ensaio. Na coluna da esquerda, o tempo designado para o teste, as posições cartesianas (X, Y e Z) do veículo no espaço de trabalho, o nível do PWM enviado para alimentar os rotores do quadricóptero e por fim as identificações numéricas do veículo e sensor utilizados naquele teste.

Figura 4.5 – Interface da aplicação para testes do sensor.



Fonte: Elaborado pelo autor.

Na coluna intermediária, temos os indicadores de temperatura e umidade advindos do sensor DHT11, conectado ao computador através de um Arduino Mega 2560. Logo abaixo, as definições do tamanho da janela para o cálculo da média móvel e o limiar utilizado para o cálculo dos *bouts* de amplitude. Reitera-se que, durante a avaliação das características do sinal, foi considerada a utilização da média móvel de algumas das características consideradas, entretanto, a metodologia não se mostrou promissora, sendo avaliadas as características dos sinais de TVOC e CO₂Eq., em seus valores instantâneos. Ainda na coluna intermediária, um indicador do nível de bateria do quadricóptero e uma chave seletora do estado da ventoinha da fonte encontram-se presentes.

Na coluna da direita, encontra-se, em sua porção superior, um conjunto de botões e indicadores para que o operador possa verificar os valores correntes e, caso necessário, enviar novos valores de *baselines* (BL) ao sensor, a partir dos quais o mesmo irá calcular os níveis de resposta de TVOC e CO₂Eq.

Logo abaixo, encontram-se quatro botões que comandam as ações de armazenamento dos dados do ensaio. O botão “*Start*” que, após acionado, dará início ao armazenamento dos dados em variáveis temporárias, o botão “*Stop*” que, quando acionado, interrompe o ensaio, descartando os dados salvos até então, e dois botões na linha de baixo, um botão “*Save*” para, após finalizado o ensaio salvar os dados em uma planilha na extensão “. xlsx” e um botão “*Discard*” para descartar os dados adquiridos no ensaio após sua finalização.

Abaixo dos botões, duas linhas indicando o estado da gravação. Na linha “*Recording*”, estará sendo exibido “*idle*” se nada estiver sendo gravado naquele momento ou “*On going*” se o ensaio estiver em andamento. Na linha “*Recording time*”, encontra-se um indicador de quantos segundos se passaram desde o início de cada ensaio.

Na parte inferior da tela, temos dois campos para inserção, por parte do operador, dos nomes da pasta e do arquivo em que os dados do ensaio serão salvos. Do lado direito das caixas de texto, encontram-se o botão “*Folder*” para seleção da pasta de salvamento, e um botão “*Close*” para fechar a janela.

4.3. Caracterização da Resposta do Sensor

Conforme apresentado anteriormente, o sensor dispõe de quatro sinais de saída: leituras cruas de H₂ e etanol, e os sinais de equivalente de CO₂ e o total de compostos orgânicos voláteis. As duas primeiras saídas têm como propósito testes e verificações e são utilizadas para alimentar os algoritmos de compensação de *baselines*, para então proverem as duas outras saídas, que são referentes à medição da qualidade do ar.

Dentre as saídas compensadas pelo *baseline*, verificou-se que a medição de TVOC mostrou-se mais responsiva à presença do gás etanol no ambiente, sendo a utilizada no decorrer deste projeto.

Em um primeiro momento foi necessário avaliar como a resposta do sensor se altera mediante a variação dos *baselines*, com o objetivo de obter padrões que apresentem características que possibilitem relacionar os dados lidos com a posição espacial do veículo em relação à fonte. Uma vez compreendida esta dinâmica, o comportamento da resposta do sensor

foi analisado mediante quatro condições: com a ventoinha de dispersão de gás ligada e desligada; e com as hélices do quadricóptero desligadas e ligadas à velocidade de pairagem, com o objetivo de descrever como a ventoinha e o empuxo gerado pelas hélices influenciam nas leituras do sensor. Por fim, foram realizados testes de caracterização da resposta em função da distância do veículo até a fonte.

4.3.1. Influência da Baseline

As *baselines* são os parâmetros a partir dos quais o sensor calcula as variáveis de qualidade do ar (TVOC e CO₂eq.) tomando como referência os valores das leituras cruas. O sensor possui a característica de ajustar as *baselines* de forma automática para melhor desempenho nas medições, sendo que para tal, o sensor deve permanecer em funcionamento por um longo período de tempo. O fabricante determina que para medições prolongadas de qualidade do ar, o sensor deve permanecer ligado por pelo menos 24 horas no ambiente desejado, para que as *baselines* se ajustem à atmosfera local. As *baselines* possuem mesmo range que as respectivas variáveis, isto é, a *baseline* para o sinal de CO₂eq., varia entre 400 e 60000 ppm, e a *baseline* para o sinal de TVOC, entre 0 e 60000 ppb.

Contudo, na aplicação desenvolvida nesta tese, o tempo de ensaio é reduzido, variando entre 2 e 5 minutos por ensaio, não havendo, portanto, a necessidade de aplicar os algoritmos de autocalibração. Ao invés disso, optou-se por utilizar as *baselines* como parâmetros de ajuste da sensibilidade da resposta do sensor e, dessa forma, otimizar a extração de características que sejam úteis para a aplicação desenvolvida neste projeto.

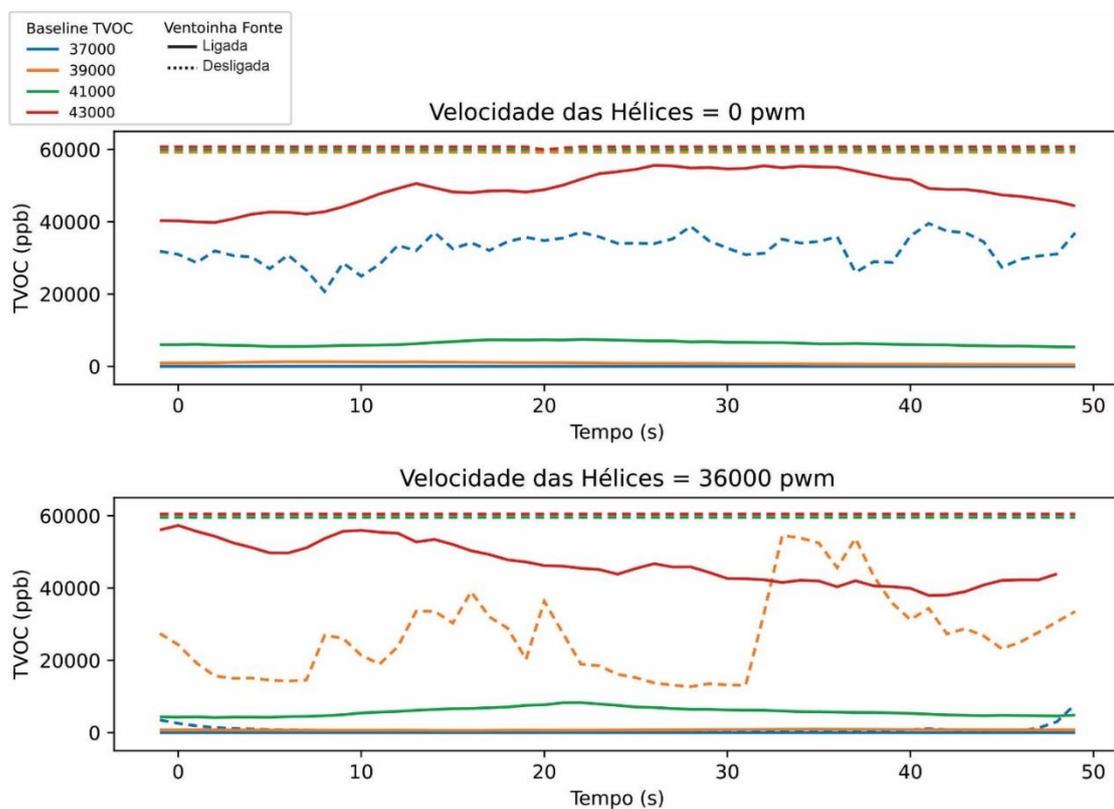
Para demonstrar a influência da *baseline* sobre o sinal de TVOC, foi proposto um ensaio no qual o quadricóptero se manteve posicionado a 50 centímetros da fonte de gás na direção de sopro da ventoinha e na mesma cota que essa. Foram escolhidos quatro diferentes valores de *baseline* (37000, 39000, 41000 e 43000) e as condições dos ensaios foram propostas seguindo as combinações de ventoinha da fonte de gás e hélices do quadricóptero desligadas e ligadas. Cada teste durou 60 segundos, sendo excluídos os 10 primeiros para evitar interferências de fenômenos predecessores. O acionamento das hélices ocorre através de um PWM controlado por um sinal de 16 bits, ou seja, a velocidade obtida pelas hélices e, portanto, o empuxo, variam em função deste valor. Para os ensaios, a hélice foi acionada em valores de PWM iguais a 36000 que é a potência correspondente ao empuxo necessário para que a aeronave fique em pairagem. Ou seja, valor em torno do qual, toda a operação do quadricóptero ocorre.

Nesta seção será discutido o comportamento da saída do sensor em função das *baselines*. A influência das hélices e da ventoinha da fonte serão detalhadas na seção 4.3.2.

Mediante os resultados presentes na Figura 4.6, observou-se que, independentemente das condições do ensaio, isto é, se a ventoinha ou as hélices estiverem ligadas ou desligadas, o aumento no valor da *baseline* ocasiona maior sensibilidade da resposta do sensor.

Isto pode ser verificado, por exemplo, analisando-se as linhas pontilhadas no gráfico inferior, isto é, com as hélices e ventoinha ligadas. Observa-se que os dois maiores valores de *baselines* ocasionaram saturação do sinal de resposta em seus valores superiores. Um valor intermediário, de 39000, fez com que o sinal não apresentasse saturação em nenhum dos extremos, já um valor menor de *baseline*, de 37000, ocasionou saturação do sinal no limite inferior. Um comportamento semelhante pode ser observado nas demais condições estipuladas para o ensaio, ou seja, independentemente da condição estudada no ensaio, o aumento no valor da *baselines* ocasiona aumento na sensibilidade do sinal de saída do sensor.

Figura 4.6 – Comportamento do sinal de TVOC a diferentes valores de *baseline*.



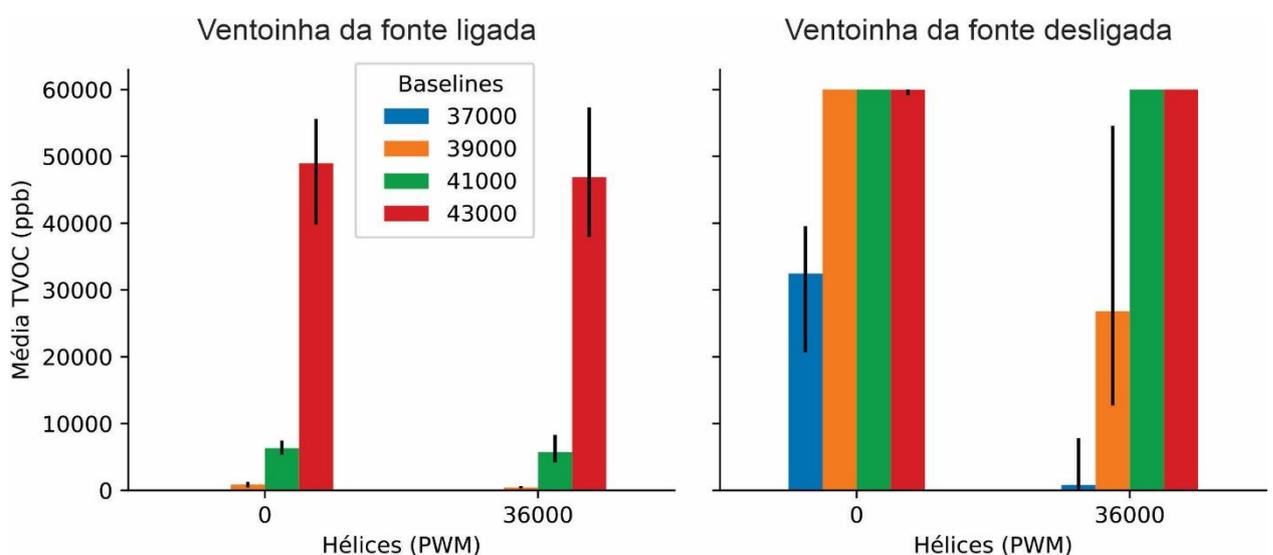
Fonte: Elaborado pelo autor.

4.3.2. Influência da Ventoinha e Hélices

A análise da influência da ventoinha e hélices sobre o sinal de resposta será facilitada ao empregarmos a visualização tal como exposta na Figura 4.7. Nesta figura, as séries temporais presentes nos gráficos da Figura 4.6, foram organizadas em gráficos de barras, tal que o comprimento de cada barra indica o valor médio do sinal e os extremos das linhas pretas, localizadas nos topos das barras, indicam os maiores e menores valores observados nas respectivas séries.

Observou-se que, para um mesmo valor de *baseline*, ao ligar a ventoinha, o sensor apresenta uma maior sensibilização, o que fica evidenciado pela elevação da média do sinal para todos as *baselines*. Em relação ao comportamento devido às hélices, não houve um padrão claro de alteração das médias das *baselines*, entretanto, foi possível notar um aumento no desvio padrão, que pode ser induzido pelo aumento no comprimento da linha preta no topo da barra, que traduz a distância entre o maior e menor valores medidos em cada série. Destaca-se que, a ausência de linhas pretas sobre algumas barras indica que o valor do sinal não variou naquele ensaio, ou seja, o sinal saturou no limite inferior ou superior, fato que pode ser corroborado pelo comportamento temporal observado pelo sinal correspondente no gráfico plotado, conforme apresentado na Figura 4.6.

Figura 4.7 – Influência da ventoinha e hélices na média e variância do sinal por *baseline*.



Fonte: Elaborado pelo autor.

Deste modo foi possível assegurar que independentemente da situação, através do ajuste das *baselines*, o sensor pode apresentar um comportamento a partir do qual características úteis podem ser extraídas para a localização da fonte de gás. Idealmente, o que se busca na aplicação proposta nesta tese, é que o sinal não deva saturar nos limites inferiores ou superiores além de necessitar apresentar elevada variância. O fato de o sinal apresentar elevada variância pode estar relacionado com o comportamento naturalmente intermitente do gás, permitindo supor que as variações bruscas observadas no sinal se relacionam com os instantes em que as moléculas do gás de interesse atingem o sensor, ocasionando a presença dos *bouts*. Neste sentido, a *baseline* de 39000 apresentou o melhor comportamento na condição de operação nominal da aeronave, isto é, com a ventoinha e hélices acionadas. Conforme as condições de saturação do etanol no ambiente, para alguns ensaios foi selecionado o valor de 39000 para o *baseline*, enquanto que para outros ensaios o valor foi ajustado para 39500, sendo que tal informação será enunciada nos testes. Não foi observado, contudo, um valor de *baseline* tal que o sinal apresente características ideais de comportamento para todas as circunstâncias testadas, havendo, portanto, necessidade de ajuste de seus valores em função das condições que se deseja operar.

4.3.3. Análise do Sinal de TVOC

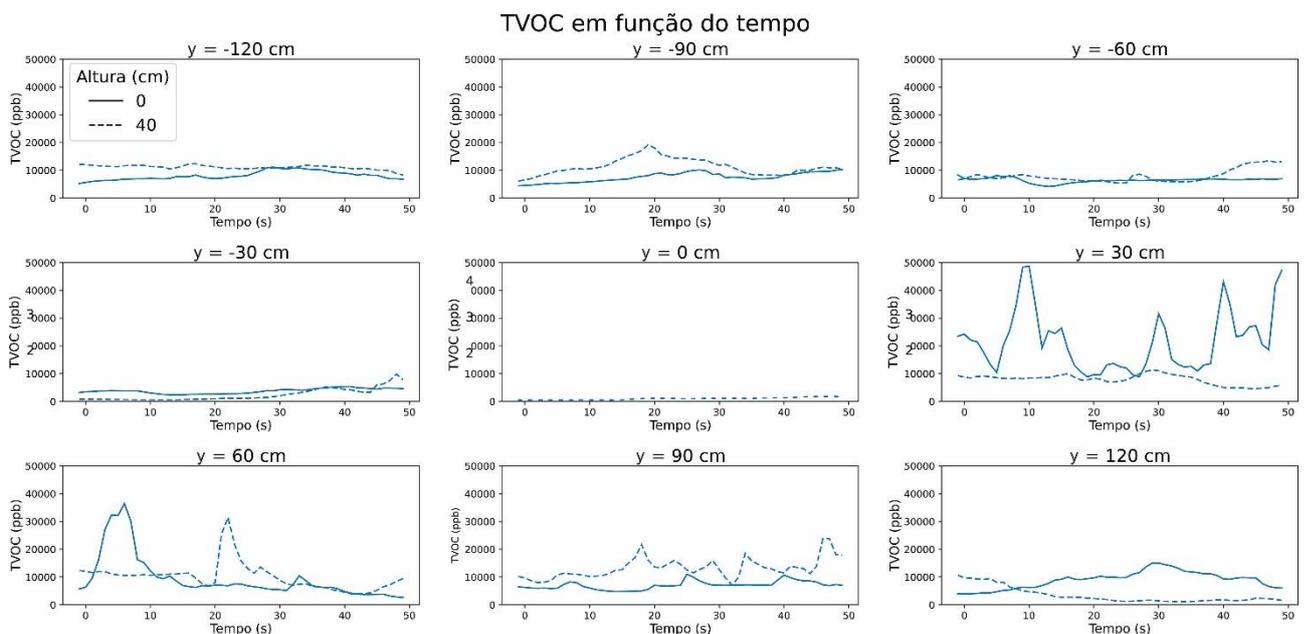
Após compreender como o sinal de TVOC varia com relação a diferentes cenários, foram realizados ensaios de caracterização, conforme as condições que se espera encontrar na prática, isto é, com um vazamento de gás ocorrendo de forma turbulenta e com as hélices do *Crazyflie* em movimento.

Na Figura 4.8 é possível observar a variação do sinal de TVOC em função da distância e altura da aeronave em relação à posição da fonte. O experimento foi planejado com a fonte de gás foi posicionada no centro do ambiente, o qual encontra-se esquematizado na Figura 4.4, e a aeronave posicionada fixamente em diferentes pontos no ambiente. Levando em consideração o sistema de coordenadas inercial com origem sobre a fonte, tal como presente na Figura 4.4, o quadricóptero foi posicionado sobre os pontos -120 cm, -90 cm, -60 cm, -30 cm, 0 cm, 30 cm, 60 cm, 90 cm e 120 cm sobre o eixo *y* em duas diferentes cotas em relação à fonte: na mesma altura (0 cm) e 40 cm acima. Durante os ensaios, a janela presente na sala permanecia aberta e a porta fechada com o objetivo de evitar acúmulo de gás etanol no ambiente sem, no entanto, possibilitar a existência de corrente de vento entre a ambas. Esta configuração repetiu-se em todos os demais ensaios. Em todos os testes, o *baseline* do TVOC foi estabelecido em

39000. A ventoinha e as hélices permaneceram ligadas, com a velocidade das hélices correspondendo ao nível que sustenta o *Crazyflie* em estado de pairagem. Em cada ponto o veículo permaneceu por 60 segundos, sendo desconsiderados os primeiros 10 segundos de cada ensaio, para evitar a influência de possíveis efeitos transitórios. Os ensaios foram repetidos três vezes em cada ponto, sendo plotados, na Figura 4.8, apenas um dos ensaios realizados o objetivo de ilustrar o comportamento observado.

Através da análise da Figura 4.8, na cota de 0 cm, verifica-se uma sensibilidade acentuada do sensor na distância de 30 cm, aparentemente diminuindo a sensibilidade à medida que o veículo se posiciona mais distante da fonte. Quando sensibilizado, o sinal exibe um comportamento intermitente. Atribui-se às subidas repentinas do sinal aos eventos em que houve choque de moléculas do gás com o sensor.

Figura 4.8 – Comportamento temporal do sinal de TVOC em função da distância até a fonte.



Fonte: Elaborado pelo autor.

Observando o comportamento do sinal para a cota de 40 cm, diferentemente do comportamento observado para a cota de 0 cm, aparentemente houve maior sensibilização do sensor a uma distância de 60 cm em comparação com as demais. Uma hipótese para esta observação consiste no fato de que como o gás está sendo ventilado no sentido positivo da coordenada Y e o mesmo possui densidade menor que a do ar. Em consequência disso, espera-

se que em uma cota acima da fonte, o sensor seja capaz de interceptar mais moléculas de gás a uma distância maior da fonte do que quanto na mesma cota que essa.

Quando comparados com o ensaio ocorrido com o veículo exatamente sobre a fonte ($Y = 0$ cm), os ensaios em posições de Y negativas exibiram maior sensibilidade, sem, entretanto, apresentarem um padrão possa relacionar-se à distância até a fonte.

Para melhor análise dos resultados obtidos nestes ensaios, foram analisadas características extraídas dos sinais exibidos na Figura 4.8, as quais serão discutidas na seção seguinte.

4.4. Extração de Informações Provenientes da Resposta do Sensor

Com o intuito de determinar a posição da fonte de gás, foram avaliados as médias e os desvios padrões das seguintes características do sinal de TVOC: valor absoluto do sinal, quantidade de *bouts*, valores dos *bouts* de amplitude e quantidade de amostras do sinal acima de um limiar, denominado como sinal elevado. Para a extração dos *bouts* e *bouts* de amplitude, foi considerado o limiar de 1000 ppb e sinais elevados foram aqueles em que a medição de TVOC encontrou-se acima de 18000 ppb.

A extração dos *bouts*, tal como proposta por Schmuker, Bahr e Huerta (2016) e aprofundada por Burgués *et al.* (2019), consiste na obtenção da derivada temporal do sinal filtrado, entretanto, ao desconsiderar a amplitude do sinal, considera-se que estejamos perdendo informação.

Conforme o trabalho de Vuka (2016), que sugeriu que a amplitude média dos *bouts* relaciona-se com a proximidade da fonte ao invés da contagem destes, o projeto apresentado nesta tese propõe uma nova metodologia de extração de *bouts*, que será aqui nomeada de *bouts* de amplitude.

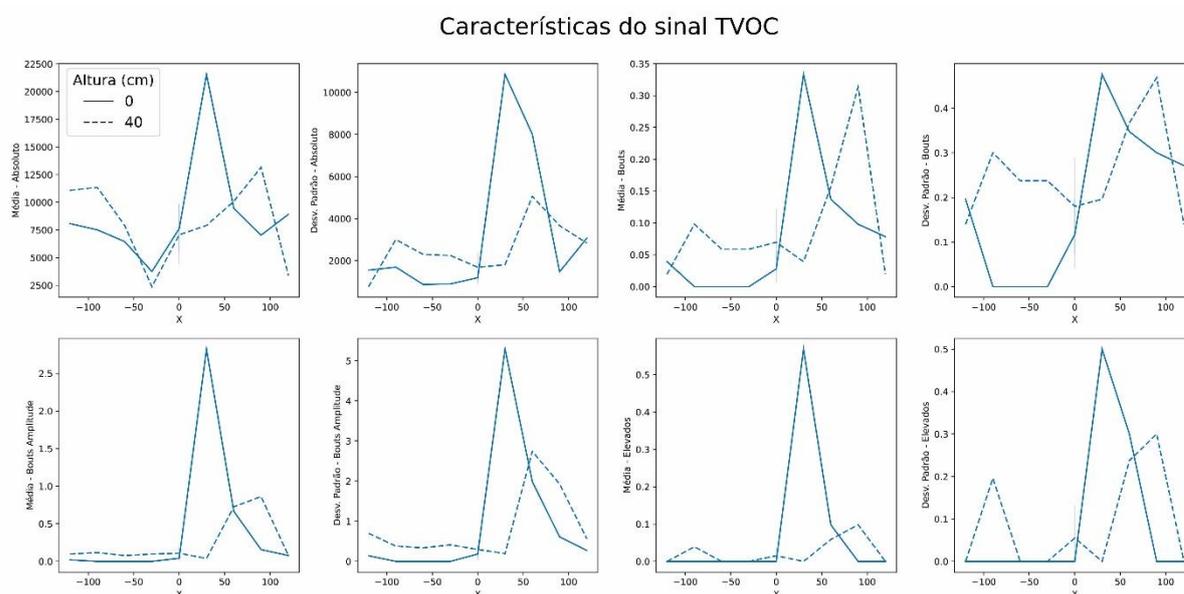
A extração dos *bouts* de amplitude considera que ao invés de todos os *bouts* terem o mesmo peso, estes agora possuam amplitudes distintas. A amplitude de cada *bout* será definida como o valor inteiro oriundo da divisão da derivada do sinal filtrado pelo limiar definido, desconsiderando o resto da divisão.

Por exemplo, supondo que o limiar de definição do *bout* do sinal de TVOC seja de 1000 ppb, e, durante os ensaios em algum momento este sinal apresenta uma subida instantânea de 5500 ppb, pelo método tradicional, teríamos registrado apenas um *bout*, enquanto no método proposto nesta tese, teríamos 5 *bouts*, desconsiderando o resto da divisão.

Neste trabalho, considerando que o sensor provê um pré-processamento dos sinais de saída, não foi necessária a utilização de filtragem para extração dos *bouts* de amplitude.

Na Figura 4.9 encontram-se os resultados dos testes realizados sobre o comportamento de cada sinal analisado. Foram realizados três ensaios em cada ponto e plotadas as médias de cada característica considerada. A evolução temporal de um dos ensaios realizados encontra-se na Figura 4.8 para ilustração.

Figura 4.9 – Ensaios para a determinação da característica a ser utilizada na estimação da posição da fonte de gás.



Fonte: Elaborado pelo autor.

Pela análise dos gráficos, considerou-se mais adequada a utilização dos *bouts* de amplitude do sinal de TVOC como indicadores da estimativa de concentração medida em cada ponto do espaço de busca. Verificou-se que esta grandeza apresentou uma relação de proporcionalidade com a distância até a fonte em ambas as alturas testadas. Através da análise da média dos *bouts* de amplitude ainda foi possível observar o efeito da dispersão do gás etanol no ambiente, cuja concentração em cotas maiores encontra-se em um patamar mais elevado para uma distância um pouco maior da fonte, corroborando o fato de como o gás se dispersa no ambiente sendo menos denso que o ar.

4.5. Algoritmo de Busca pela Fonte de Odor

O algoritmo proposto considera a abordagem do mapeamento da distribuição de gás, ao invés da busca reativa pela fonte. Para tal, será considerada a aplicação de uma trajetória que será iterativamente reduzida à razão áurea em cada dimensão ao final de cada iteração, com o centro do novo volume situado sobre a estimativa da fonte. O critério de parada será o tamanho do volume explorado e a declaração da fonte de odor será feita através de uma rede neural artificial (RNA). Para a realização dos testes, considerou-se que a fonte de odor induzia as plumas de etanol fixamente no sentido positivo do eixo Y .

Algoritmo 1: Método de mapeamento da distribuição de gás

```

1: Define ambiente XYZ = [dim_X, dim_Y, dim_Z]
2: Thread 1:
3:   do:
4:     Vertices = Calcula_poligono(XYZ, centro)
5:     Vertices = Rotaciona_poligono(Vertices)
6:     for SP in Vertices:
7:       diff = Calcula_Diferença (pos_atual, SP)
8:       while (diff > 0.1):
9:         pos_alvo = Planeja_Trajectoria(SP, pos_atual)
10:        CF.Envia_Comando(pos_alvo)
11:        Thread 2:
12:          Pos_atual = CF.Leitura_Posição
13:          TVOC = CF.Leitura_TVOC
14:          kde = Mapeamento_Gaussiano(Pos_atual, TVOC)
15:          estimativa_fonte = RNA(Kde)
16:          Espera (1000ms)
17:          Espera (2000ms)
18:          diff = Calcula_Diferença(Pos_atual, SP)
19:        end while
20:      end for
21:      XYZ = Reduz_Aurea(XYZ, max(kde))
22: while (Volume(XYZ) > limiar_volume)

```

4.5.1. Trajetória

No início do Algoritmo 1 são declaradas as dimensões do ambiente de busca. Em seguida, as funções “Calcula_Poligono” e “Rotaciona_Poligono” geram as referências que o veículo irá seguir. A primeira função, contida na linha 4, é responsável por, a partir das dimensões do ambiente e da posição de seu centro, gerar uma sequência de referências que

setpoints não obedeceu a nenhum critério de otimização, sendo proposta com o intuito de cobrir um volume relativamente grande em uma trajetória curta.

O planejador de trajetórias foi desenvolvido por meio da abordagem de campos potenciais artificiais, que foi modificada através da inserção de um campo rotacional. Isto, é, além dos obstáculos produzirem um campo repulsivo, eles também produzem um campo rotativo com o objetivo de evitar que o agente fique preso em mínimos locais. O campo rotativo, também referenciado como campo de vórtice, apresenta rotação tridimensional tal que o sentido de giro sobre cada eixo cartesiano é determinado automática e individualmente para cada par robô-obstáculo porventura presente no espaço de trabalho. O cálculo para tal baseia-se na posição relativa o obstáculo em relação ao segmento de reta que conecta o robô ao alvo. O algoritmo ocorre de modo *online* e é acionado para traçar a rota entre cada *setpoint*.

Seguindo na linha 10, o algoritmo envia cada *setpoint* ao *Crazyflie* e, enquanto ele executa a trajetória, todos os dados do voo, como as posições no espaço e as leituras de *bouts* de amplitude são continuamente adquiridos em uma frequência de 1 Hz em uma *thread* a parte (linhas 11 a 16 do algoritmo 1). Este laço é repetido até que o veículo se aproxime a uma distância inferior a 0,1 m do vértice perseguido. Na sequência, o robô perseguirá o próximo vértice de forma iterativa até que todos os vértices tenham sido visitados (laço *for* definido na linha 6 do algoritmo 1).

Uma vez que o todos os vértices do volume foram visitados, um novo volume de busca será gerado (linha 21 do algoritmo 1), tendo como centro o ponto de maior probabilidade calculada no ambiente (a ser detalhado na seção 4.5.2), o qual corresponde à uma boa aproximação da posição da fonte, e cujas dimensões são individualmente reduzidas à razão áurea, isto é, divididas por 1,6180. O processo de redução do volume de busca em torno do ponto de maior estimativa de probabilidade segue iterativamente até que o volume de busca gerado possua volume inferior a 1 m^3 . O valor de 1 m^3 foi escolhido por representar um volume pequeno o suficiente para que novas medições realizadas pelo quadricóptero em seu interior não tragam ganho significativo de informação para construção do mapa. Neste instante, o veículo pousa em segurança e a declaração da fonte ocorre tal como detalhado na seção 4.5.3.

Considerando que cada *Crazyflie* possui um limite seguro de 4 minutos de voo, relevando o acréscimo do peso e do consumo de energia do sensor, e uma bateria com meia vida, cada aeronave poderá inspecionar um espaço de aproximadamente 20 m^3 de volume, sabendo que a velocidade média nos ensaios é de 0,25 m/s. Neste caso, para o mapeamento de

áreas maiores, o espaço deverá ser segmentado em áreas menores, ficando cada uma a ser explorada por um veículo diferente.

A utilização de mais de uma aeronave na mesma área traz problemas como a interferência mútua dos rastros das hélices. Muitos estudos abordaram o problema da interferência das hélices oriundo de um quadricóptero, entretanto não há na literatura muitos resultados acerca da utilização de dois ou mais veículos em um mesmo espaço. Assim, esta tese considera que, para espaços maiores com volume superior a 20 m^3 , a divisão do espaço entre diferentes veículos é a abordagem mais adequada ao invés de empregar mais de uma aeronave compartilhando a busca em um mesmo espaço.

4.5.2. Extrapolação por Kernel Gaussiano

Neste trabalho, optou-se pelo uso de um algoritmo de extrapolação devido à restrição de tempo de voo das aeronaves. As medições realizadas em cada ponto do ambiente correspondem a leituras de pontos muito específicos, de modo que a aplicação de um procedimento de extrapolação espacial é capaz de inferir sobre a concentração nos pontos em que não houve medição. Desta forma, o algoritmo não depende de uma grande cobertura do espaço de busca. Outra vantagem é que o método é capaz de lidar, até um certo grau, com a integração temporal e espacial que surge quando um sensor de óxido de metal realiza medições sucessivas sem resguardar o tempo de recuperação (LILIENTHAL, LOUFI e DUCKETT, 2006).

Como parte da solução aqui proposta, o processo de extrapolação para gerar um mapa de distribuição de gás é realizado através do método de estimação da densidade de probabilidade utilizando um kernel gaussiano. As medições de *bouts* de amplitude são assumidas como sendo amostras de uma distribuição gaussiana da concentração de gás (medida pelos *bouts* de amplitude) centrada na fonte. Não será adotada nenhuma premissa acerca dos parâmetros da distribuição gaussiana assumida da fonte, desta forma este trabalho não realizará a estimativa destes parâmetros.

A estimação de densidade por kernel (KDE, do inglês *kernel density estimation*) é um método não paramétrico para estimar a função de densidade de probabilidade de uma variável aleatória. O método também é referido como *Parzen-Rosenblatt window*.

O método é aplicado a partir da Eq. 4.1, em que $\hat{f}_h(x)$ representa a função de densidade estimada, n é a quantidade de amostras medidas, x_i representa a população das amostras

extraídas, h é o parâmetro de suavização e K é a função de kernel, que neste trabalho será representada pela função gaussiana, Eq. 4.2, na qual σ é o desvio padrão, σ^2 é a variância da distribuição e μ representa a média. O termo K_h simboliza a função de kernel suavizada pela constante h .

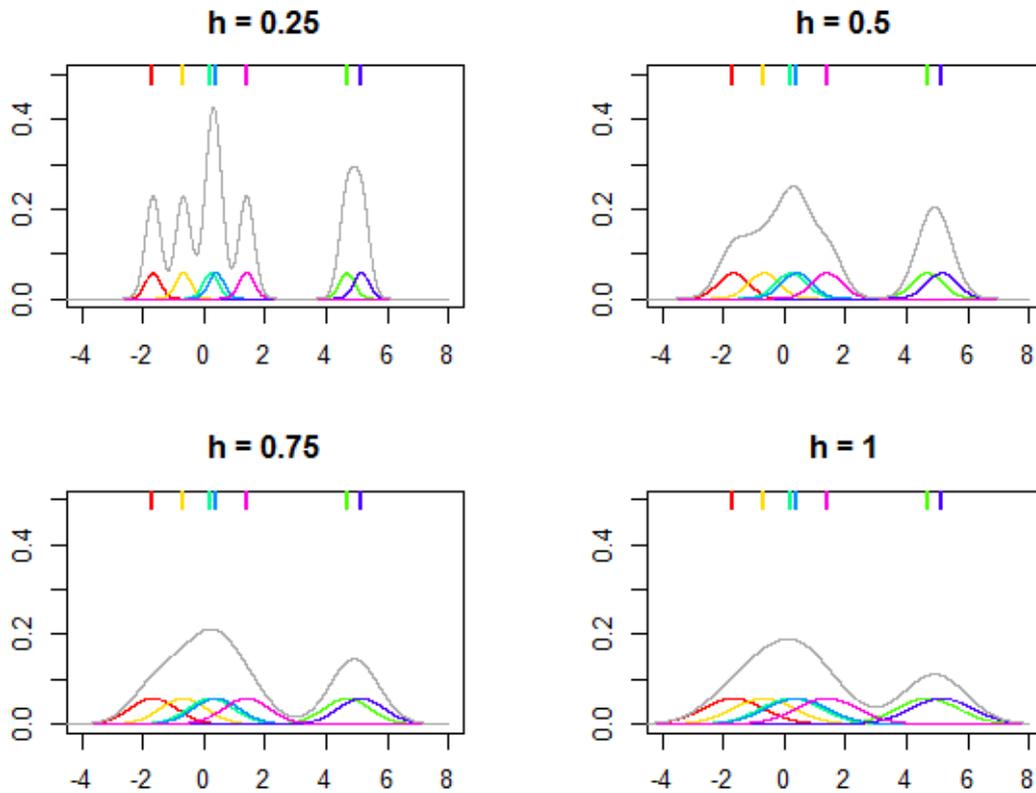
$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) = \frac{1}{n} \sum_{i=1}^n K_h(x - x_i) \quad (4.1)$$

$$g(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2} \frac{(x - \mu)^2}{\sigma^2}\right) \quad (4.2)$$

Os algoritmos de suavização por kernel em geral são altamente dependentes da escolha do parâmetro de suavização. Um valor muito elevado pode acentuar demasiadamente a suavização, podendo incorrer em perda de informação em algum ponto no espaço, já valores muito pequenos podem tornar a função de estimativa muito ruidosa, conforme a Figura 4.11. Nesta figura, as amostras representadas pelos pontos na parte superior dos gráficos produzem, cada uma, uma função gaussiana com a respectiva cor. Com o coeficiente de suavização (h) muito baixo, as funções de kernel possuirão baixa variância e a função de estimação de densidade na cor cinza possuirá formato mais irregular. Com o coeficiente mais elevado, verifica-se uma função de densidade mais suave.

Na presente tese, a função de densidade será estimada a partir de amostras ponderadas, relevando a conclusão do trabalho de Vuka (2016). As amostras que alimentarão a estimação serão ponderadas pelos valores dos *bouts* de amplitude. Para implementação foi utilizada a classe `gaussian_ked()` da biblioteca `scipy` disponível para Python. Além disso, como se trata de um problema multivariável, foi utilizada uma extensão multivariável da equação da estimação por kernel, tal como presente na Eq. 4.3. Em problemas deste tipo, um parâmetro de suavização na forma do coeficiente de correlação deve ser adicionado, além de ser necessário assegurar que os dados possuam posto completo, caso contrário, a análise estatística não poderá ser explorada (SCOTT, 1992). No algoritmo aqui proposto, caso os dados utilizados para alimentar o estimador não possuam posto completo (o que foi verificar ocorrer, normalmente, no início dos ensaios quando não há, ainda, detecção de muitos *bouts*), a estimação não é realizada para aquela amostragem, aguardando a atualização dos dados para ser novamente realizada. Nesta equação, o parâmetro w_i corresponde à medição no ponto i normalizada junto ao vetor com as demais medições.

Figura 4.11 – Influência do valor da variável de suavização da função de estimação de densidade por kernel.



Fonte: Disponível em <https://stats.stackexchange.com/questions/244012/can-you-explain-parzen-window-kernel-density-estimation-in-laymans-terms>. Acesso em 13 de março de 2022.

A largura de banda (BW) teve seu valor definido de forma automática pela regra de ouro utilizando o fator Scott, a partir da Equação 4.4. A partir deste valor, computa-se a matriz de covariância, a partir da qual será calculado o fator de suavização como a raiz quadrada de seu determinante. Na equação, n é o número de amostras e d é a dimensão, no caso $d = 3$.

$$\hat{f}_h(x, y, z) = \frac{1}{n} \sum_{i=1}^n w_i K_{hx}(x - x_i) K_{hy}(y - y_i) K_{hz}(z - z_i) \quad (4.3)$$

$$BW = n \left(\frac{-1}{d + 4} \right) \quad (4.4)$$

O mapa de distribuição de gás é atualizado após cada medição realizada pelo veículo. Embora este trabalho não se propõe a segmentação do volume de busca, como forma de tornar

o algoritmo menos dispendioso e mais acurado, após cada estimação da função de densidade suas estimativas são calculadas para um número finito de pontos no espaço de busca.

O espaço foi segmentado em 10 pontos por eixo, totalizando 1000 pontos totais. O ponto de maior valor da função densidade estimada é então utilizado cada vez que o algoritmo performa a redução do volume de busca.

4.5.3. Declaração da Fonte

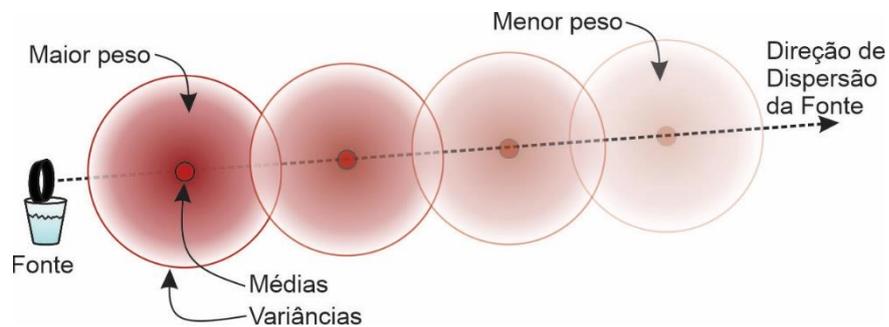
O processo de declaração da fonte neste trabalho é realizado com o auxílio de um algoritmo inteligente, também referenciado como inteligência artificial. Embora a estimação de densidade por kernel gaussiano provê uma boa estimativa da proximidade da fonte, conforme observado na literatura (LILIENTHAL e DUCKETT, 2004), o ponto de máximo da estimação tende a não ocorrer sobre a fonte em si, mas em suas proximidades. Partindo desta premissa, esta tese propõe refinar o resultado das estimações realizadas pela função de densidade utilizando um algoritmo regressor de aprendizagem.

Para o treinamento das redes neurais, um simulador simplificado foi desenvolvido sob as seguintes premissas:

- o gás emanado da fonte possui a mesma densidade que o ar;
- a concentração do gás a partir da fonte decresce a uma razão exponencial de constante -1;
- o gás se dispersa a um desvio padrão constante.

O simulador consiste em um gerador de pontos distribuídos no espaço tridimensional a partir de várias funções gaussianas com médias distribuídas em um segmento de reta que parte da fonte e se direciona no mesmo sentido em que a ventoinha assopra o gás. A primeira função possui sua média localizada a uma distância de 0,5 m da fonte, havendo novas funções com médias a cada 0,2 m até 2,0 m. Todas as funções possuem desvio padrão de 0,4 m. Estes parâmetros foram estimados empiricamente a partir de comparações com a dispersão observada durante os ensaios experimentais. Em cada simulação são gerados 100 pontos, sendo descartados aqueles que se encontram fora dos limites do ambiente. Uma ilustração esquemática do princípio do simulador encontra-se na Figura 4.12.

Figura 4.12 – Simulador de dispersão de odor simplificado, não observadas proporções.



Fonte: Elaborado pelo autor.

Com os dados obtidos do simulador, duas estratégias de treinamento foram propostas, cada uma implementada por duas diferentes classes de algoritmos de aprendizagem: uma rede neural artificial *perceptron* multicamadas (RNAPM) e uma técnica de aprendizagem de máquina que consiste em um regressor de múltiplas saídas baseado em gradiente *boosting* (RMSGB). A RNAPM possui uma camada oculta com 100 neurônios e foi treinada utilizando a função de ativação unidade linear retificada. O RMSGB foi treinado utilizando o erro quadrático médio como critério.

A primeira estratégia consiste em treinar as redes neurais tendo como entradas as posições (coordenadas X , Y e Z) e os valores da concentração, representados pelas leituras dos *bouts* de amplitude. Primeiramente, as amostras geradas pelo simulador são filtradas, removendo todas aquelas que possuam um escore padronizado inferior a 0,3. Em seguida, são selecionados os cinco pontos de maior concentração, sendo, portanto, alimentada com 20 dados.

A segunda estratégia consiste em empregar a estimação de função de densidade calculada sobre todos os pontos gerados pelo simulador, realizar a filtragem considerando apenas os pontos com escore padronizado superior a 0,3 e então tomados novamente os cinco maiores valores retornados pela estimação com as respectivas posições no espaço, resultando em um número igual de 20 entradas. Foi escolhida a quantidade de cinco maiores valores e filtragem por escore padronizado superior a 0,3 por observar que estes parâmetros aparentemente proveram melhor comportamento nos ensaios, não tendo sido implementado, portanto, nenhum método de otimização para estes valores. O uso do escore padronizado se mostrou útil como forma de filtragem pela entropia, de modo que em ensaios em que não há amostras com escore padronizado superior a 0,3, considera-se que a informação sobre a posição da fonte encontra-se demasiada dispersa pelo ambiente (elevada entropia), não havendo

segurança suficiente para declarar sua localização. Já as saídas dos padrões que alimentam as RNAs consistem nas três coordenadas da posição espacial da fonte, para ambas estratégias utilizadas.

Como demonstração, as estratégias executadas por ambas as RNAs foram testadas 20 vezes. Cada teste consistiu em o simulador gerar 30 padrões de testes (20 entradas e 3 saídas cada), sendo cada um repetido 10 vezes, totalizando 300 padrões. Os padrões foram separados em uma razão de 80% para treinamento e 20% para testes. O objetivo da repetição é fazer com que as redes neurais aprendam diferentes padrões de distribuição das amostras geradas pelo simulador para uma mesma posição da fonte no espaço, tornando-as mais robustas e capazes de identificar diferentes padrões de dispersão para uma mesma posição da fonte. Como critério de proximidade, adotou-se a distância cartesiana entre as estimativas e as posições reais da fonte em cada padrão. Os resultados dos experimentos encontram-se na Tabela 4.2.

Tabela 4.2 – Resultados das estratégias de treinamento.

Estratégia	Estratégia 1	Estratégia 1	Estratégia 2	Estratégia 2
Rede	RNAPM	RMSGB	RNAPM	RMSGB
Nomenclatura	RNAPM	RMSGB	RNAPM-KDE	RMSGB-KDE
Erro máximo (m)	0,3154	0,3109	0,2816	0,2511
Erro mínimo (m)	0,2616	0,2469	0,2112	0,1926
Erro médio (m)	0,2883	0,2828	0,2407	0,2159

Fonte: Elaborado pelo autor.

O algoritmo de declaração formado pelas RNAs treinadas foi utilizado em duas abordagens distintas. A primeira abordagem consiste em sua utilização de forma *online*, no tempo dos ensaios, e ocorre à cada nova estimativa de probabilidade realizada pela função KDE. A segunda abordagem refere-se a utilizar o declarador de posição de modo *offline*, isto é, uma vez encerrado o ensaio, o algoritmo dotado de todos os dados adquiridos, infere sobre a posição da fonte. Os resultados de ambas abordagens são apresentados no capítulo 5.

CAPÍTULO 5

RESULTADOS E DISCUSSÕES

Neste capítulo, os resultados dos ensaios de mapeamento e declaração da fonte de odor serão apresentados e discutidos.

5.1. Declaração da Fonte *Online*

Por declaração da fonte *online*, entende-se que a subarefa de declaração da fonte de odor ocorre durante a execução dos ensaios.

Foram realizados oito ensaios envolvendo o mapeamento e a declaração da fonte no ambiente, tais como descritos no capítulo 4 e cujos resultados encontram-se dispostos na Tabela 5.1. A abordagem da declaração da fonte de maneira *online* utilizou redes neurais treinadas com amostras alimentadas pelo simulador. A escolha pelas RNAs a serem utilizadas na declaração *online* ocorreu ao observar o desempenho das quatro categorias de redes neurais quando submetidas aos testes com os dados oriundos de experimentos com o veículo real. Embora, pela análise da Tabela 4.2, a técnica RMSGB-KDE tenha apresentado melhores resultados quando testadas com os padrões do simulador, optou-se pela RNAPM-KDE, devido ao seu desempenho quando testadas com amostras colhidas nos experimentos práticos. Destes treinamentos foram escolhidas seis redes neurais dentre as que obtiveram menor erro médio de estimação.

Para avaliação, será considerada na análise dos resultados a última estimação realizada no ensaio.

Tabela 5.1 – Sumário dos resultados dos ensaios.

Ensaio	Posição Real da fonte [m] [x y z]	Estimação pela função de densidade de probabilidade		Estimação pelo algoritmo de aprendizagem	
		Posição[m]	Erro [m]	Posição [m]	Erro [m]
		[x y z]		[x y z]	
1	[0,21 -1,03 0,7]	[-1,5 -1,7 0,7]	1,8375	[-0,34 -0,02 -0,41]	1,6401
2	[0,21 -1,03 0,7]	[-1,5 -1,7 0,7]	1,3292	[0,86 -0,24 -0,39]	1,1241
3	[0,16 -0,8 1,0]	[0,16 0,18 1,42]	1,0752	[0,11 0,22 0,83]	1,0378
4	[0,16 -0,8 1,0]	[0,16 0,56 0,98]	1,3667	[0,24 0,10 0,62]	0,9847
5	[0,73 -1,8 1,0]	[0,5 0,56 1,85]	2,5270	[0,54 0,41 0,72]	2,2431
6	[-0,72 -1,67 0,93]	[-0,5 -0,94 0,84]	0,7629	[-0,36 -0,36 0,11]	1,5798
7	[-0,68 -0,23 0,95]	[-0,16 0,18 1,27]	0,7392	[-0,19 -0,43 1,14]	0,5624
8	[0,0 -0,66 0,75]	[0,16 -0,18 0,7]	0,5022	[0,10 0,14 0,33]	0,9132
Média	---	---	1,2674	---	1,2606

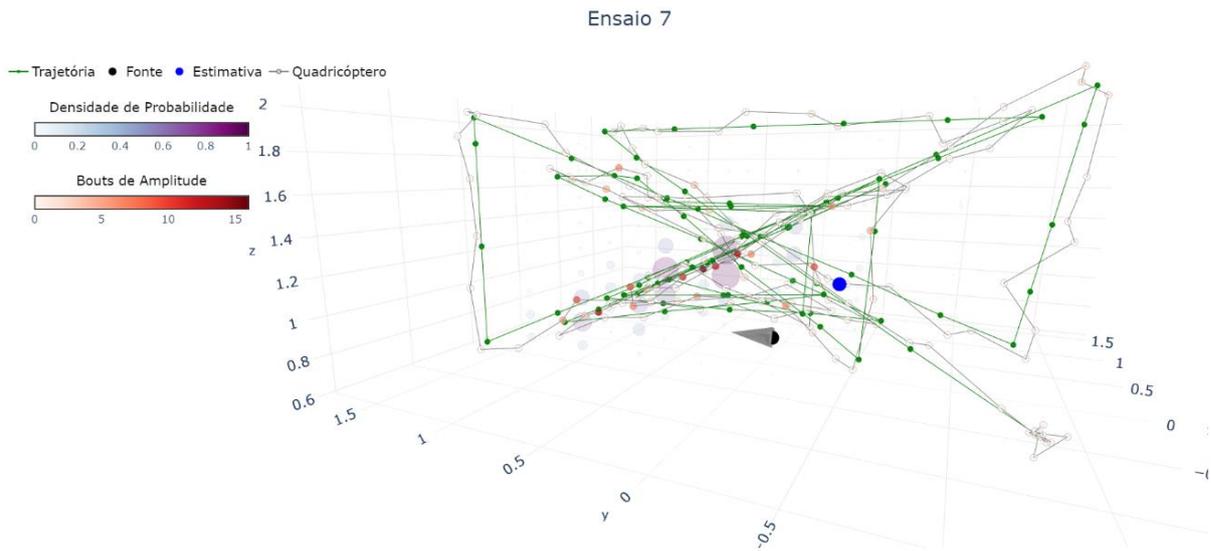
Fonte: Elaborado pelo autor.

Observa-se que a estimação realizada pelo algoritmo de aprendizagem obteve melhor resultado em relação à função de densidade de probabilidade em 75% dos ensaios, obtendo uma média de erro ligeiramente menor. Entretanto, observou-se durante a maioria dos ensaios que a rede neural foi capaz de estimar a posição da fonte com erros ainda menores em algum momento durante a execução dos experimentos.

Como exemplo, serão apresentados dois ensaios, o ensaio 7 que apresentou menor erro de estimativa e o ensaio 5 cujo erro foi o maior observado. Nas respectivas figuras, a rota gerada pelo algoritmo de planejamento de trajetórias encontra-se na cor verde. A trajetória realizada pelo *Crazyfly* na cor cinza e a fonte na cor preta com o cone cinza indicando a direção de sopro da ventoinha. Na trajetória em cinza, a cor de cada ponto representa a leitura de *bouts* de amplitude realizada em cada aquisição. Os círculos em tonalidade púrpura indicam a estimativa de densidade de probabilidade no ambiente, tendo seus diâmetros e a intensidade das cores proporcionais à probabilidade de localização da fonte estimada para cada região. Embora a estimação se dê de forma contínua, a representação discretizada utilizando esferas translúcidas foi escolhida para melhor visualização.

O ensaio 7, o qual apresentou melhor resultado com erro de estimativa final de 0,5624 m, encontra-se visualmente descrito na Figura 5.1. Ao longo do ensaio, a melhor estimação obtida foi de 0,3995 m, conforme visualizado na Figura 5.2.

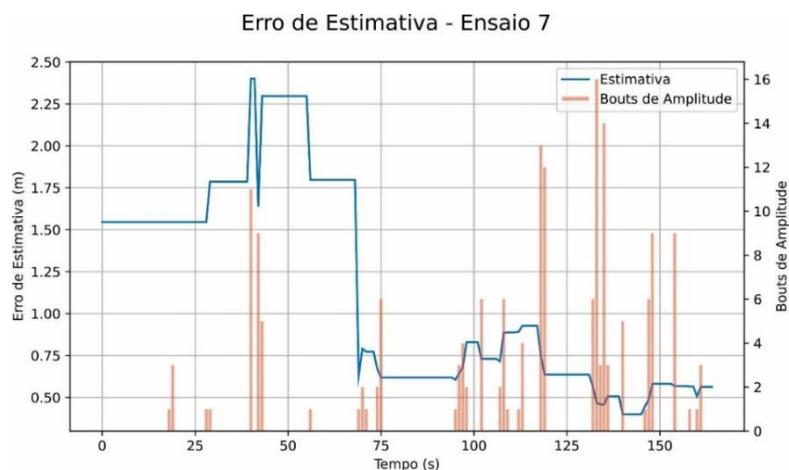
Figura 5.1 – Demonstração gráfica do ensaio 7.



Fonte: Elaborado pelo autor.

Observa-se que à medida que o ensaio evolui, a estimativa reage aos eventos de detecção dos *bouts* de amplitude, demonstrando tendência em convergir para a posição real da fonte à medida que mais informação são adquiridas. Entretanto, na porção final do ensaio, por volta de 140 segundos, em que houve detecção de novos *bouts* com maior amplitude, o estimador apresentou deterioração na estimação. Este efeito aparenta ser resultado de treinamentos realizados com um simulador pouco preciso com o que se apresenta na realidade. Outra hipótese para este fenômeno parte do fato das detecções terem ocorrido em regiões ligeiramente mais distantes da fonte, a ser detalhada neste capítulo.

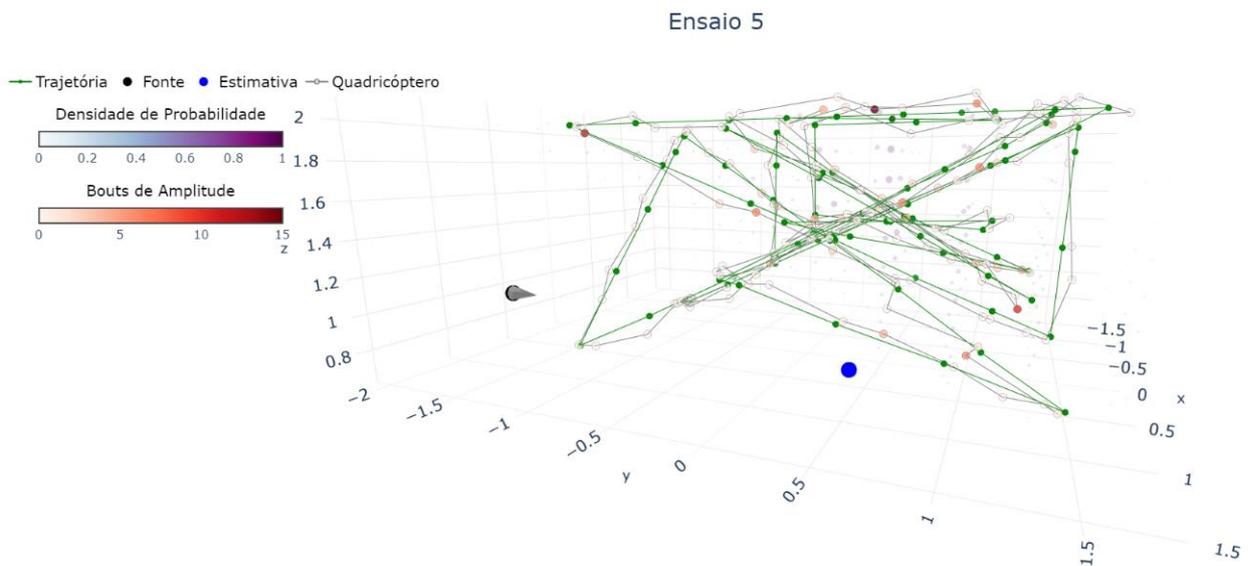
Figura 5.2 – Evolução do erro de estimativa durante o ensaio 7.



Fonte: Elaborado pelo autor.

O resultado do ensaio 5, o qual apresentou pior desempenho em relação aos demais, encontra-se graficamente plotado na Figura 5.3. Observa-se que a função de densidade de probabilidade foi incapaz de estimar valores mais elevados para a distribuição de concentração. Uma hipótese a ser avaliada para esta observação se pauta no fato de ter havido maior entropia de informação em relação ao ensaio 7, ou seja, houve uma estimaco mais dispersa no ambiente. Isto pode estar relacionado à menor amplitude média observada por *bouts*. No ensaio 7, foram detectados 38 *bouts* com amplitude média de 4,63, já no ensaio 5, 47 *bouts* foram adquiridos com amplitude média de 3,02. A partir da observaco deste fenômeno, pode-se induzir que a qualidade das estimaces se relaciona com a média da amplitude dos *bouts* ao invés da quantidade de *bouts* detectados. A interpretaço física disso se pauta na entropia do sinal detectado. Espera-se que quanto maiores as amplitudes, mais informaço sobre a proximidade da fonte se obtém e, portanto, menor a entropia da informaço desejada.

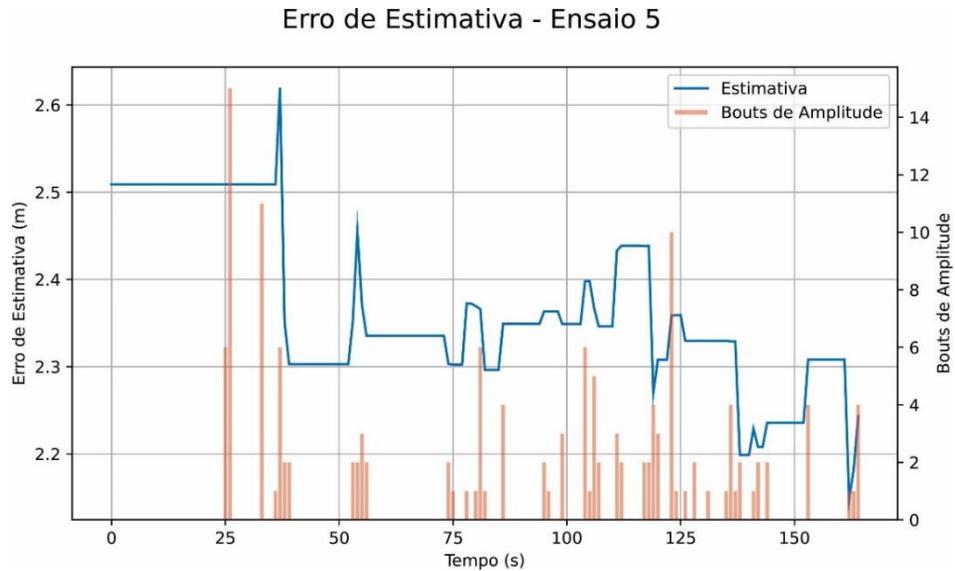
Figura 5.3 – Demonstraco gráfrica do ensaio 5.



Fonte: Elaborado pelo autor.

A evoluço temporal da estimaco do ensaio 5, Figura 5.4, corrobora a ideia de que a estimaco responde aos eventos de detecço de *bouts*. Observa-se que os *bouts* adquiridos no ensaio 5 possuem menor média de amplitude em relaço àqueles obtidos no ensaio 7, embora o número de detecçes seja maior.

Figura 5.4 – Evolução do erro de estimativa durante o ensaio 5.



Fonte: Elaborado pelo autor.

Uma possível explicação para a detecção de médias menores de *bouts* se pauta no fato da rota predefinida não ser capaz de interceptar muitos pacotes de odor e, com isso, não ser capaz de detectar informação relevante em situações de maior entropia da informação sobre a distância até a fonte. Isso evidencia um dos problemas do método escolhido, que é o fato de propor uma rota fixa durante a operação de mapeamento ao invés de empregar a abordagem da busca reativa. Eventualmente, a rota proposta pode não ser capaz de agregar informação suficiente para estimar a localização da fonte em algumas posições no ambiente.

Entretanto, a hipótese que aparentemente se mostra mais verdadeira, e que também pode explicar a deterioração da estimação observada na porção final do ensaio 7, consiste na interpretação de que, devido à natureza turbulenta do ar, a detecção dos *bouts* de amplitude nem sempre é assegurada nas regiões em que se espera obter maior concentração de gás. Uma forma didática de compreender o fenômeno da influência das hélices é entender o problema sob uma perspectiva probabilística. Considerando a varredura do ambiente utilizando veículos terrestres, por exemplo, uma componente de probabilidade já se encontra presente na detecção de gás pelo sensor devido à natureza turbulenta da pluma de dispersão. Isto é, por maior que seja a concentração de moléculas em uma região, ainda assim existe uma chance menor que 100% de haver colisão entre as moléculas do gás de interesse e o sensor quando o veículo trafega pelo ambiente. Com o uso de aeronaves de asas rotativas, esta chance tende a diminuir devido ao efeito das hélices, de tal forma que a maior captação de *bouts* pode não ocorrer nas regiões onde espera-se haver maior concentração de odor, isto é, na vizinhança da fonte.

Uma consequência desta hipótese é o fato de que o algoritmo de busca aqui proposto se torna susceptível à não detecção de *bouts* nas regiões próximas à fonte. Assim, mesmo que se faça uso do método de redução do volume de busca em torno do ponto de maior concentração, objetivando adquirir mais informação em regiões próximas à fonte, se as estimativas iniciais de concentração de gás iniciais não forem acuradas, o volume convergirá para regiões distantes da posição real da fonte e, com isto, a estimação ficará comprometida.

Uma solução possível seria utilizar alguma variável ou parâmetro para inferir sobre a qualidade da estimação realizada e, a partir desta, propor, ao invés da convergência do volume de busca, seu aumento temporário, objetivando aumentar a certeza das estimações sobre a posição da fonte e, somente após um valor de certeza considerado satisfatório, voltar a diminuir o volume de busca na iteração seguinte.

Contudo, a partir da análise dos resultados presentes na Tabela 5.2, observa-se que, aparentemente, nenhuma das variáveis apresentadas demonstra relação com o desempenho do algoritmo. Foram avaliados a quantidade de *bouts* lidos, a soma de suas magnitudes bem como as amplitudes médias, o maior valor, a média e o desvio padrão dos valores da última função de densidade de probabilidade calculada nos ensaios, bem como a norma do vetor de autovalores da matriz de covariância, a qual relaciona-se como uma medida do quão espacialmente espalhadas estão as amostras, relacionando-se à entropia da função de KDE.

Com isso, induz-se que, a princípio, nenhuma destas variáveis tem potencial para relacionar-se com o desempenho do algoritmo e, provavelmente, não seriam boas opções para serem utilizadas como forma de encerramento da busca utilizando a estratégia pautada no mapeamento apresentada neste trabalho. Por este motivo, o volume da área de busca foi utilizado como parâmetro de encerramento. Considera-se, entretanto, que a quantidade de ensaios realizados deva ser maior para que os dados analisados possuam maior significância.

De modo geral, considerou-se que o resultado obtido apresentou um desempenho satisfatório, considerando que esta tese utilizou a abordagem do mapeamento da distribuição de gás sem dividir o espaço de busca em áreas menores, utilizando os algoritmos inteligentes como regressores para estimar a posição da fonte. Na literatura, observa-se que, geralmente, os trabalhos fazem uso da segmentação do espaço de trabalho, permitindo a utilização de algoritmos inteligentes como solução a um problema de classificação.

Tabela 5.2 – Apresentação dos resultados.

Ensaio	<i>Bouts</i>	Soma <i>Bouts</i>	Média <i>Bouts</i>	Max KDE	Média KDE	Des. Pad. KDE	Norma autovaloes covariância	Erro KDE	Erro RNA
1	29	173	5,9655	2,1353	0,0439	0,1705	0,3759	1,8375	1,6401
2	41	186	4,5365	1,5915	0,0525	0,1613	0,3835	1,3292	1,1241
3	28	163	5,8214	1,4399	0,0543	0,1702	0,3	1,0752	1,0378
4	26	111	4,2692	0,9462	0,0476	0,1283	0,4878	1,3667	0,9847
5	47	142	3,0212	0,5144	0,0463	0,0864	0,5438	2,527	2,2431
6	38	224	5,8947	1,5685	0,0726	0,1463	0,4437	0,7629	1,5798
7	38	176	4,6315	2,4441	0,0539	0,2155	0,3186	0,7392	0,5624
8	41	222	5,4146	0,7046	0,0322	0,0805	0,55	0,5022	0,9132

Fonte: Elaborado pelo autor.

Entretanto, os resultados apontam que é possível obter um desempenho melhor utilizando as abordagens aqui apresentadas. Para isto, considerou-se a realização da operação de declaração da fonte de modo *offline*.

5.2. Declaração da Fonte *Offline*

Os resultados obtidos nos ensaios *online* se deram através da utilização de algoritmos inteligentes treinados e testados com dados oriundos do simulador, sendo escolhida a categoria de algoritmos de aprendizagem que melhor desempenho obteve em testes com dados de experimentos físicos. Todavia, visando melhorar o desempenho da declaração de fonte, será avaliada a possibilidade desta tarefa ser realizada ao final do ensaio, após mapeado todo o ambiente. Para isto, serão utilizadas três abordagens distintas:

5.2.1. Treinamento e Seleção pelo Simulador

A primeira solução apresentada ao problema da declaração *offline* da fonte consiste em utilizar as redes neurais, anteriormente enumeradas, treinadas pelos os padrões gerados pelo simulador. Para este procedimento, novos treinamentos foram realizados, de modo que redes neurais diferentes daquelas utilizadas na estimação *online* e cujos resultados encontram-se na Tabela 4.2, foram implementadas. A seleção dos melhores algoritmos inteligentes de cada tipo ocorreu após avaliação do desempenho dos mesmos quando testados com padrões oriundos do

mesmo simulador, na razão de 20% dos padrões gerados em cada sessão de treinamento. A metodologia do processo de treinamento segue a mesma metodologia descrita no Capítulo 4 – Metodologia, em que foram gerados 300 padrões, com a fonte localizada em 30 posições diferentes com repetição de 10 simulações em cada posição.

5.2.2. Treinamento pelo Simulador e Seleção pelos Dados Experimentais

A abordagem de treinamento pelo simulador e seleção pelos dados experimentais emprega redes neurais que foram treinadas com as mesmas amostras oriundas do simulador tal como apresentado na seção 5.2.1. Entretanto, o critério de seleção das mesmas obedecerá ao erro médio obtido quando testadas com os padrões oriundos de sete dos oito ensaios experimentais realizados, sendo excluído o ensaio 5 por apresentar erro de estimação destoante dos demais. Desta forma, as RNAs que, porventura, apresentaram menor erro médio nos testes envolvendo amostras do simulador podem não necessariamente serem as mesmas redes neurais que apresentaram melhor resultado com as amostras dos experimentos práticos.

5.2.3. Treinamento e Seleção pelos Dados Experimentais

A última categoria de redes neurais foi treinada utilizando somente os dados gerados nos experimentos. O objetivo desta abordagem é eliminar a imperfeição que existe entre o simulador e a realidade, além de ser possível avaliar o quão adequado o simulador desenvolvido é para representar o fenômeno de dispersão de gás aqui estudado. Para seleção das melhores RNAs, novamente os dados do ensaio 5 foram desconsiderados. Dos sete ensaios restantes, cinco foram utilizados para treinamento e dois para os testes, em separações aleatórias em cada seção de treinamento.

5.3. Considerações Finais

Os erros de estimação obtidos pelos melhores algoritmos de cada categoria sobre os dados de cada um dos oito ensaios, incluindo o ensaio 5 para avaliação, encontram-se dispostos na Tabela 5.3.

Tabela 5.3 – Erros do treinamento dos algoritmos inteligentes.

Rede	Treinamento	Teste - Seleção	1	2	3	4	5	6	7	8	Media
RNAPM	Simulador	Simulador	0,7761	0,7924	0,3241	0,6022	1,9311	1,3973	0,8435	0,3981	0,8831
RMSGB	Simulador	Simulador	0,8420	0,8719	0,6757	0,7743	2,3499	1,5506	0,6668	0,5613	1,0366
RNAPM-KDE	Simulador	Simulador	0,9073	0,9333	1,0586	0,6794	1,5941	1,8443	1,1001	0,4645	1,0727
RMSGB-KDE	Simulador	Simulador	0,6900	0,7779	0,5972	0,5815	1,5734	1,4742	0,8164	0,4405	0,8689
RNAPM	Simulador	Experim.	0,6074	0,5031	0,2204	0,7516	1,7678	0,7254	0,7499	0,3055	0,7039
RMSGB	Simulador	Experim.	0,7608	0,7480	0,5514	0,8352	2,0692	1,4293	0,4982	0,5743	0,9333
RNAPM-KDE	Simulador	Experim.	0,7530	0,7212	0,9902	0,5779	1,7198	0,6432	0,3268	0,2323	0,7455
RMSGB-KDE	Simulador	Experim.	0,5252	0,4784	0,4424	0,4809	1,7382	0,9657	0,8430	0,3372	0,7264
RNAPM	Experim.	Experim.	(0,0421)	0,0849	(0,0479)	(0,0184)	0,9161	(0,0249)	0,0719	(0,0191)	0,3577*
RMSGB	Experim.	Experim.	0,1356	(0,0000)	0,0480	(0,0000)	1,3287	(0,0000)	(0,0000)	(0,0000)	0,5041*
RNAPM-KDE	Experim.	Experim.	(0,0725)	(0,1741)	(0,1124)	(0,1137)	0,9853	0,2661	(0,1688)	0,4390	0,5635*
RMSGB-KDE	Experim.	Experim.	0,1063	(0,0000)	(0,0000)	0,0874	1,1241	(0,0000)	(0,0000)	(0,0000)	0,4393*
Media	---	---	0,6104	0,6568	0,5453	0,5967	1,5915	1,1440	0,6574	0,4170	---

Fonte: Elaborado pelo autor.

Os valores de média das redes neurais treinadas e testadas com dados experimentais aparecem destacados com um asterisco, porque eles foram calculados considerando apenas os erros obtidos nos testes com os ensaios não empregados nos respectivos treinamentos. Da mesma forma, a média dos erros dos ensaios na última linha da tabela não considerou os erros dos ensaios cujos padrões foram utilizados nos treinamentos, os quais tendem a 0 e que se encontram destacados entre parênteses.

Observa-se, contudo, que as RNAs treinadas e testadas com dados experimentais apresentaram desempenho superior em relação às correspondentes treinadas pelo simulador, o que indica que o simulador escolhido não apresenta comportamento próximo ao observado na realidade.

Não foi observada diferença significativa de desempenho entre os algoritmos de RNA *perceptron* multicamadas e de aprendizagem de máquina de regressão por *gradient boosting*. Entretanto, é possível observar que os algoritmos de aprendizagem de máquina tiveram melhor desempenho quando aplicados sobre a função KDE, enquanto as redes neurais *perceptron* tiveram desempenho melhor quando utilizadas com as medições de *bouts* de amplitude.

Em relação aos ensaios, verificou-se que o ensaio 5 obteve pior média de estimação, enquanto o ensaio 8 o melhor desempenho.

De forma geral, é possível concluir que o emprego de algoritmo inteligente é capaz de melhorar o desempenho da estimação. Na Tabela 5.4, encontram-se os erros médios de

estimação das abordagens verificadas neste trabalho. Como não foi verificada diferença significativa entre o desempenho das redes neurais *perceptron* e de gradiente *boosting* treinadas para os *bouts* de amplitude e para a densidade de probabilidade, nesta análise não será feita distinção entre elas. O erro da estimação realizada utilizando unicamente a função de KDE foi comparado com os erros médios das estimações realizadas pelas RNAs, sendo discernida a abordagem utilizada para o treinamento e teste delas. Na abordagem *online*, encontra-se, além da função KDE, uma coluna designada para as RNAs treinadas e selecionadas pelo desempenho nos testes com os padrões gerados pelo simulador (Sim-Sim). Na abordagem de utilização da rede neural após o mapeamento, além das redes neurais Sim-Sim, encontram-se aquelas que foram treinadas com dados do simulador e selecionadas pelos testes com os dados dos ensaios experimentais (Sim-Exp) e aquelas treinadas e selecionadas com dados advindos dos experimentos (Exp-Exp).

Tabela 5.4 – Erros médios de estimação para cada abordagem.

Abordagem	Online		Offline			
	Ensaio	KDE [m]	Redes Sim-Sim [m]	Redes Sim-Sim [m]	Redes Sim-Exp [m]	Redes Exp-Exp [m]
1		1,8375	1,6401	0,8039	0,6616	0,1210
2		1,3292	1,1241	0,8439	0,6127	0,0849
3		1,0752	1,0378	0,6639	0,5511	0,0480
4		1,3667	0,9847	0,6593	0,6614	0,0874
5		2,5270	2,2431	1,8621	1,8237	1,0886
6		0,7629	1,5798	1,5666	0,9409	0,2661
7		0,7392	0,5624	0,8567	0,6045	0,0719
8		0,5022	0,9132	0,4661	0,3623	0,4390
Média		1,2674	1,26065	0,9653	0,7773	0,4661

Fonte: Elaborado pelo autor.

Verificou-se que o emprego dos algoritmos inteligentes melhorou a estimação quando realizada unicamente pela KDE. O emprego de métodos offline, contudo, trouxe melhorias significativas no desempenho observado. Como esperado, quando as redes neurais são treinadas com os dados dos próprios experimentos, o desempenho aumenta significativamente. Releva-se que, as médias apresentadas na Tabela 5.4 para as redes neurais Exp-Exp, foram contabilizadas apenas os padrões não utilizados nos treinamentos de cada rede neural.

CAPÍTULO 6

CONCLUSÃO

Este trabalho apresentou um sistema de detecção de fonte de odor utilizando nanoquadricóptero. A solução apresentada consiste em utilizar aeronaves de tamanho reduzido para explorar o ambiente com o objetivo de construir um mapa de distribuição de odor tridimensional e, a partir deste, ser capaz de estimar a posição da fonte.

Foi utilizada uma aeronave *Crazyflie* embarcada com um sensor de qualidade do ar SGP30, entretanto, foi proposta uma metodologia de cooperação entre duas ou mais aeronaves, que consiste em segmentar o espaço de busca, atribuindo cada porção a uma única aeronave.

O modelo do sensor foi escolhido, dentre aqueles que se enquadravam para a operação, por possuir a possibilidade de ajuste do nível de sensibilidade das saídas de qualidade do ar medidas e, a partir disso, condicionar o sinal para um nível em que características pudessem ser extraídas.

Para o problema da influência das hélices sobre a dispersão de gás no ambiente, foi proposta a extração dos *bouts* de amplitude sobre o sinal de TVOC. Os *bouts* de amplitude são as subidas bruscas do sinal pré-filtrado pelo sensor, quantificadas a partir da divisão por um limiar pré-estabelecido. Através de ensaios, foi observado que esta característica se relaciona diretamente com a distância até a fonte.

Para o planejamento de trajetória da aeronave, foi utilizado um método que consiste na abordagem modificada dos campos potenciais artificiais. O algoritmo, detalhado no trabalho de De Souza *et al.* (2022), consiste na inserção de campos rotativos nos obstáculos como solução ao problema de mínimos locais. Cada campo rotativo apresenta sentido de rotação sobre os três eixos cartesianos e o sentido sobre cada um é determinado através do cálculo da posição espacial do respectivo objeto em relação ao robô e ao alvo.

A abordagem do mapeamento, escolhida para este trabalho, foi aplicada a partir do condicionamento do veículo a uma rota exploratória predefinida, com o objetivo de otimizar a cobertura do ambiente. Como solução ao fato de o veículo possuir limitado tempo de voo, foi proposto que o volume de interesse reduza de forma iterativa em torno do ponto de maior estimativa sobre a posição da fonte. Assim, embora todo o ambiente seja explorado, a aeronave se concentra na exploração das regiões próximas à provável localização da fonte, salvando tempo de ensaio.

O mapeamento da distribuição de gás neste estudo foi realizado utilizando uma função de estimativa de densidade de probabilidade por meio de um kernel gaussiano. A partir das amostras coletadas, a função atualiza a distribuição espacial de probabilidade de localização da fonte. A estimativa é utilizada como referência para o algoritmo de redução do volume de busca e foi realizada de modo contínuo ao invés de segmentar o ambiente, atribuindo uma probabilidade da fonte a cada célula, como é comumente proposto na literatura. Considerando que a distribuição dos *bouts* de amplitude não atinge seu máximo exatamente na posição da fonte, algoritmos inteligentes foram propostos para refinar a estimativa, atuando na sub tarefa de declaração da fonte de odor.

Foram analisadas uma rede neural *perceptron* multicamada e um regressor gradiente *boosting* estimando a posição da fonte, tanto a partir da distribuição dos *bouts* de amplitude no espaço quanto sobre a distribuição da densidade de probabilidade. Os padrões de treinamento foram gerados por um simulador simples de distribuição de odor e também a partir de experimentos reais. A acurácia das RNAs foi testada nas abordagens *online* e *offline*.

Para os experimentos, considerou-se uma fonte de odor com turbulência induzida em uma direção fixa. Foram realizados oito experimentos, com a fonte posicionada em diferentes pontos, em um ambiente em formato de prisma retangular com dimensões úteis de 2,30 m x 3,50 m x 1,80 m e volume de 14,49 m³. Embora, devido ao tempo de voo, o ensaio seja restrito a, no máximo, 250 segundos, o algoritmo possui possibilidade de escala com o emprego de mais de uma aeronave segmentando o espaço de busca em regiões menores sob a responsabilidade de cada agente.

Com a realização dos ensaios, foi observado que o algoritmo, embora tenha sido capaz de convergir o volume de busca em torno da posição real da fonte na maioria dos testes, apresentou elevada dependência da detecção de *bouts* na proximidade da fonte. Desta forma, quando a rota predefinida não é capaz de otimizar a captação ao redor da fonte, a construção do mapa de distribuição fica comprometida e, em consequência, o algoritmo de redução do volume

de busca acaba forçando o veículo a sobrevoar regiões com pouca concentração, afetando o desempenho da declaração.

Sobre a etapa de declaração da fonte de odor conclui-se que o emprego de algoritmos inteligentes melhorou a acurácia da estimação da fonte quando comparados com a estimação realizada unicamente pelo mapeamento. Além disso, foi verificado que a utilização de dados advindos dos testes experimentais para treinamento das redes neurais apresentou consistiu em uma estratégia de treinamento com melhor desempenho quando comparada com a estratégia de treinar o algoritmo inteligente com os padrões oriundos do simulador.

Em suma, o algoritmo proposto foi capaz de realizar estimação da fonte de odor, sob as condições propostas, de maneira eficiente, sendo capaz de obter média de erro de estimação de até 0,46 m em um ambiente de volume aproximado de 15 m³.

6.1. Trabalhos Futuros

Como complemento ao algoritmo de localização de fonte de odor proposto nesta tese, pretende-se ampliar sua utilização para áreas maiores utilizando mais aeronaves. Primeiramente, dever-se-á considerar o limite seguro de tempo de voo para o modelo de aeronave utilizado neste trabalho, que consiste em aproximadamente 4 minutos. Assim, considerando uma velocidade média de 0,25 m/s e a redução iterativa do volume de busca, concluímos que cada aeronave tem a capacidade de explorar uma área de até 20 m³ de volume. Relevando as particularidades de cada ambiente, a segmentação deverá ocorrer respeitando este limite de volume para cada aeronave.

Já com o objetivo de melhorar o desempenho do algoritmo, algumas tarefas ou linhas de investigação serão propostas.

Primeiramente, considerando o resultado presente na Tabela 5.4, uma melhoria no simulador deverá ser investigada, seja através de ajustes nos parâmetros, seja utilizando outros modelos mais robustos. Na literatura, o simulador GADEN, proposto por Monroy *et al.* (2017), emerge como uma alternativa para simular não apenas a dispersão do gás, mas para emular uma plataforma de testes virtual capaz de avaliar e comparar algoritmos de busca diversos.

Além disso, mais ensaios se fazem necessários para gerar mais padrões de treinamento e assim aumentar a robustez das estimativas. Em um segundo momento, diferentes direções de dispersão da fonte deverão ser testadas e os desempenhos das redes neurais deverão ser avaliados para elas. Pretende-se, com isso, obter um algoritmo que seja capaz de detectar

padrões em vazamentos de gás para quaisquer direções no ambiente. Ainda sobre o ambiente, pretende-se incluir obstáculos para avaliar a capacidade do algoritmo de planejamento de rotas em obter caminhos seguros capazes de prover uma boa estimativa para a fonte. Para isto, um algoritmo de aprendizagem profunda ou aprendizagem reforçada deverá ser considerado.

Outra linha de investigação possível para este trabalho inclui investigar algum critério que seja capaz de calcular a acurácia da estimação da posição da fonte realizada pelo algoritmo. Com este critério estabelecido, será possível aumentar a certeza da estimação *online* e efetuar a declaração no tempo do ensaio com melhor desempenho, relevando, principalmente, os ensaios em que houve estimação mais precisa durante sua execução em relação à estimação final. Com isso, espera-se que o algoritmo se torne mais ágil e preciso na abordagem de declaração no tempo de execução.

Por fim, pretende-se investigar o uso de estratégias de busca reativas, comparando diferentes algoritmos e avaliando a robustez ao efeito do rastro das hélices sobre a dispersão de odor inicial. Nesta linha, os algoritmos probabilísticos baseados em redução da entropia da informação emergem como prováveis soluções. Nesta linha, o emprego de algoritmos de aprendizagem reforçada também se faz digno de investigação. Nesta tese observou-se o ganho de acurácia com o emprego de algoritmos inteligentes, sendo esperado obter desempenho ainda melhor com uso de algoritmos inteligentes mais robustos.

REFERÊNCIAS BIBLIOGRÁFICAS

ANDERSON, M. J.; SULLIVAN, J. G.; TALLEY, J. L.; BRINK, K. M.; FULLER, S. B.; DANIEL, T. L. The “Smellicopter,” a bio-hybrid odor localizing nano air vehicle. In *Proceedings of the 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, p. 6077-6082, 2019. DOI: <https://doi.org/10.1109/IROS40897.2019.8968589>.

ARKIN, R. *Behavior-based robotics*. Bradford Book, 1998.

BAU, J.; CARDÉ, R. T. Modeling optimal strategies for finding a resource-linked, windborne odor plume: theories, robotics, and biomimetic lessons from flying insects. *Integrative and Comparative Biology*, 55(3), p. 461–477, 2015. DOI: <https://doi.org/10.1093/icb/icv036>.

BAYAT, B.; CRASTA, N.; LI, H.; IJSPEERT, A. Optimal search strategies for pollutant source localization. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2016. DOI: <https://doi.org/10.1109/iros.2016.7759287>.

BAYAT, B.; CRASTA, N.; CRESPI, A.; PASCOAL, A. M.; IJSPEERT, A. Environmental monitoring using autonomous vehicles: a survey of recent searching techniques. *Current Opinion in Biotechnology*, v. 45, p. 76–84, 2017. DOI: <https://doi.org/10.1016/j.copbio.2017.01.009>.

BILGERA, C.; YAMAMOTO, A.; SAWANO, M.; MATSUKURA, H.; ISHIDA, H. Application of convolutional long short-term memory neural networks to signals collected from a sensor network for autonomous gas source localization in outdoor environments. *Sensors*, 18(12), 4484. 2018. DOI: <https://doi.org/10.3390/s18124484>.

BITCRAZE. *Crazyflie Start Here*. Disponível em: <https://www.bitcraze.io/start>. Acesso em: 20 de novembro de 2020a.

BITCRAZE. *Bitcraze Wiki*. Disponível em: <https://wiki.bitcraze.io/>. Acesso em: 15 de novembro de 2020b.

BLANCO, J. L.; MONROY, J. G.; LILIENTHAL, A.; GONZALEZ-JIMENEZ, J. A Kalman filter based approach to probabilistic gas distribution mapping. In *Proceedings of the 28th Annual ACM Symposium on Applied Computing*. 2013. DOI: <https://doi.org/10.1145/2480362.2480409>.

BOUABDALLAH, S. *Design and control of quadrotors with application to autonomous flying*. PhD Thesis, École Polytechnique Fédérale de Lausanne, Lausanne, 2007.

BROOKE-HOLLAND, L. *Unmanned Aerial Vehicles (Drones): An Introduction*; House of Commons Library: London, UK, 2012.

BURGUÉS, J.; HERNÁNDEZ V.; LILIENTHAL, A. J.; MARCOET, S. Smelling nano aerial vehicle for gas source localization and mapping. *Sensors*, v. 19, n. 478, p. 1-25, 2019. DOI: <https://doi.org/10.3390/s19030478>.

BURGUÉS, J.; MARCO, S. Environmental chemical sensing using small drones: A review. *Science of The Total Environment*, 141172. 2020. DOI: <https://doi.org/10.1016/j.scitotenv.2020.141172>.

BURGUÉS, J.; ESCLAPEZ, M.D.; DOÑATE, S.; PASTOR, L.; MARCO, S. Aerial mapping of odorous gases in a wastewater treatment plant using a small drone. *Remote Sensing*, v. 13. 2021. DOI: <https://doi.org/10.3390/rs13091757>.

CASTILLO, P.; LOZANO, R.; DZUL, A. *Modelling and control of mini-flying machines*. Springer-Verlag, Londres, 2005.

CASTRO, A.; MAGNEZI, N.; SINTAYEHU, B.; QUINTO, A.; ABSHIRE, P. Odor source localization on a nano quadcopter. In *Proceedings of the IEEE Biomedical Circuits and Systems Conference (BioCAS)*. Cleveland, Ohio, 2018. DOI: <https://doi.org/10.1109/BIOCAS.2018.8584769>.

CHEN, X.; HUANG, J. Odor source localization algorithms on mobile robots: a review and future work. *Robotics and Autonomous Systems*, v. 112, p. 123-136, 2019. DOI: <https://doi.org/10.1016/j.robot.2018.11.014>.

CHEN, X.; FU, C.; HUANG, J. A deep q-network for robotic odor/gas source localization: modeling, measurement and comparative study. *Measurement*, 183, 109725. 2021. DOI: <https://doi.org/10.1016/j.measurement.2021.109725>.

CONSI, T. R.; ATEMA, J.; GOUDEY, C. A.; CHO, J.; CHRYSOSTOMIDIS, C. AUV guidance with chemical signals. In *Proceedings of the IEEE Symposium on Autonomous Underwater Vehicle Technology*, Cambridge, USA, p. 450-455, 1994. DOI: <https://doi.org/10.1109/AUV.1994.518659>.

COQUET, C.; ARNOLD, A.; BOUVET, P.-J. Control of a robotic swarm formation to track a dynamic target with communication constraints: analysis and simulation. *Applied Sciences*, v.11, n. 3179, 2021. DOI: <https://doi.org/10.3390/app11073179>.

COURY, M.; LIMA, G. V.; SOUSA, G. F.; SANTOS, M. K.; SOUZA, R. M.; SILVA, A. S. Parameterization and experimental control of a mini quadcopter. In *Proceedings of the 25th ABCM International Congress of Mechanical Engineering*, Uberlândia, 2019.

CRASTA, N.; MORENO-SALINAS, D.; BAYAT, M.; PASCOAL, A. M.; ARANDA, J. Optimal motion planning algorithm using range-only information in the presence of unknown currents. In *Proceedings of the IFAC Conference on Control Applications in Marine Systems (CAMS)*, p. 41-47. Trondheim, Norway. 2016. DOI: <https://doi.org/10.1016/j.ifacol.2016.10.319>.

DE CROON, G. C.; O'CONNOR, L. M.; NICOL, C.; IZZO, D. Evolutionary robotics approach to odor source localization. *Neurocomputing*, v. 121, p. 481-497. 2013. DOI: <https://doi.org/10.1016/j.neucom.2013.05.028>.

DE SOUZA, R.M.; LIMA, G.V.; MORAIS, A.S.; OLIVEIRA-LOPES, L.C.; RAMOS, D.C.; TOFOLI, F.L. Modified artificial potential field for the path planning of aircraft swarms in three-dimensional environments. *Sensors*, 22, 1558, 2022. DOI: <https://doi.org/10.3390/s22041558>

DENNLER, N.; RASTOGIA, S.; FONOLLOSA, J.; VAN SCHAIK, A.; SCHMUKER, M. Drift in a popular metal oxide sensor dataset reveals limitations for gas classification benchmarks. *Sensors and Actuators B: Chemical*, v. 361, 2022. DOI: <https://doi.org/10.1016/j.snb.2022.131668>

DHT11. *DHT11 Humidity and Temperature Sensor*. Disponível em: <https://www.mouser.com/datasheet/2/758/DHT11-Technical-Data-Sheet-Translated-Version-1143054.pdf>. Acesso em: 25 de março de 2021.

DI LELLO, E.; TRINCAVELLI, M.; BRUYNINCKX, H.; DE LAET, T. Augmented switching linear dynamical system model for gas concentration estimation with MOX sensors in an open sampling system. *Sensors*, 14(7), 12533-12559. 2014. DOI: <https://doi.org/10.3390/s140712533>.

DO, S.; LEE, M.; KIM, J.-S. The effect of a flow field on chemical detection performance of quadrotor drone. *Sensors*, 20(11), 3262. 2020. DOI: <https://doi.org/10.3390/s20113262>.

DUISTERHOF, B.; LI, S.; BURGUÉS, J.; JANAPA, V. J.; CROON, G. Sniffy bug: a fully autonomous swarm of gas-seeking nano quadcopters in cluttered environments. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2022. DOI: <https://doi.org/10.1109/IROS51168.2021.9636217>.

DUNKLEY, O.; ENGEL, J.; STURM, J.; CREMERS D. Visual-inertial navigation for a camera-equipped 25 g nano-quadrotor. In *Proceedings of the IROS Aerial Open-Source Robotics Workshop*. Chicago, USA, p. 4-5, 2014.

ERCOLANI, C.; TANG, L.; HUMNE, A. A.; MARTINOLI, A. Clustering and informative path planning for 3D gas distribution mapping: algorithms and performance evaluation. In *Proceedings of the IEEE Robotics and Automation Letters*, v. 7, n. 2, p. 5310-5317, 2022. DOI: <https://doi.org/10.1109/LRA.2022.3154026>.

EU, K. S.; YAP, K. M. Chemical plume tracing. *International Journal of Advanced Robotic Systems*, 15(1), 2018. DOI: <https://doi.org/10.1177/1729881418755877>.

FARAH, A.; DUCKETT, T. Reactive localisation of an odour source by a learning mobile robot. In *Proceedings of the Second Swedish Workshop on Autonomous Robotics*. Stockholm, Sweden. 2002.

FARID, Z.; NORDIN, R.; ISMAIL, M. Recent advances in wireless indoor localization techniques and system. *Journal of Computer Networks and Communications*, p. 1-12, 2013. DOI: <https://doi.org/10.1155/2013/185138>.

FARRELL, J. A.; MURLIS, J.; LONG, X.; LI, W.; CARDÉ, R. T. Filament-based atmospheric dispersion model to achieve short time-scale structure of odor plumes. *Environmental Fluid Mechanics*, v. 2, n. 1, p. 143-169, 2002. DOI: <https://doi.org/10.1023/A:1016283702837>.

FARRELL, J. A.; PANG, S.; LI, W. Plume mapping via hidden Markov methods. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 33, n. 6, p. 850-863, 2003. DOI: <https://doi.org/10.1109/TSMCB.2003.810873>.

FATÉS, N. Collective infotaxis with reactive amoebae: a note on a simple bio-inspired mechanism. *Cellular Automata - ACRI*, v. 9863, 2016. DOI: https://doi.org/10.1007/978-3-319-44365-2_15.

FISPQ - ETANOL ANIDRO COMBUSTÍVEL EAC. *Ficha de Informações de Segurança de Produto Químico*. Disponível em: <https://www.vibraenergia.com.br/sites/default/files/2021-09/fispq-comb-etanol-etanol-anidro-combustivel-eac.pdf>. Acesso em: 20 de outubro de 2021.

FRONCZEK, J. W.; PRASAD, N. R. Bio-inspired sensor swarms to detect leaks in pressurized systems. In *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, p. 1967-1972, v. 2, 2005. DOI: <https://doi.org/10.1109/ICSMC.2005.1571435>.

GAURAV, K.; KUMAR, A.; SINGH, R. Single and multiple odor source localization using hybrid nature-inspired algorithm. *Sādhanā*, p. 45:83, 2020. DOI: <https://doi.org/10.1007/s12046-020-1318-3>.

GRASSO, F. W.; DALE, J. H.; CONSI, T. R.; MOUNTAIN, D. C.; ATEMA, J. Behavior of purely chemotactic Robot lobster reveals different odor dispersal patterns in the jet region and the patch field of a turbulent plume. *Biological Bulletin*, v. 191, n. 2, p. 312–313, 1996. DOI: <https://doi.org/10.1086/BBLv191n2p312>.

HAIJEGHRARY, H.; HSIEH, M. A.; SCHWARTZ, I. B. Multi-agent search for source localization in a turbulent medium. *Physics Letters A*, v. 380, n. 20, p. 1698-1705, 2016. DOI: <https://doi.org/10.1016/j.physleta.2016.03.013>.

ISHIDA, H.; SUETSUGU, K.; NAKAMOTO, T.; MORIIZUMI, T. Study of autonomous mobile sensing system for localization of odor source using gas sensors and anemometric sensors. *Sensors and Actuators A*, v. 45, n. 2, p. 153-157, 1994. DOI: [https://doi.org/10.1016/0924-4247\(94\)00829-9](https://doi.org/10.1016/0924-4247(94)00829-9).

ISHIDA, H.; WADA, Y.; MATSUKURA, H. Chemical sensing in robotic applications: a review. *IEEE Sensors Journal*, v. 12, n. 11, p. 3163-3173, 2012. DOI: <https://doi.org/10.1109/JSEN.2012.2208740>.

JING, T.; MENG, Q-H.; ISHIDA, H. Recent progress and trend of robot odor source localization. In *Proceedings of the IEEJ Transactions on Electrical and Electronic Engineering*, v. 16, p. 938–953, 2021. DOI: <https://doi.org/10.1002/tee.23364>.

KEMPER, M.; FATIKOW, S. Impact of center of gravity in quadrotor helicopter controller design. In *IFAC Proceedings Volumes*, v. 39, n. 16, p. 157–162, 2006. <https://doi.org/10.3182/20060912-3-DE-2911.00030>.

- KIM, H.; PARK, M.; KIM, C. W.; SHIN, D. Source localization for hazardous material release in an outdoor chemical plant via a combination of LSTM-RNN and CFD simulation. *Computers & Chemical Engineering*, 125, 476–489. 2019. DOI: <https://doi.org/10.1016/j.compchemeng.2019.03.012>.
- KOVADLO, G.; RUSSEL, R. A. Robot odor localization: a taxonomy and survey. *The International Journal of Robotics Research*, v. 27, n. 8, p. 869-894, 2008. DOI: <https://doi.org/10.1177/0278364908095118>.
- KUROTSUCHI, K.; TAI, M.; TAKAHASHI, H. Vision-based autonomous micro-air-vehicle control for odor source localization. In *Proceedings of the 23rd International Conference on Mechatronics and Machine Vision in Practice (M2VIP)*. Nanjing, China, 2016. DOI: <https://doi.org/10.1109/M2VIP.2016.7827276>.
- LANDRY, B. *Planning and control for quadrotor flight through cluttered environments*. Master Thesis, Massachusetts Institute of Technology, Massachusetts, 2015.
- LI, R.-G.; WU, H.-N. Quantum-behaved multi-robot plume source localization with formation maintenance and obstacle avoidance. In *Proceedings of the 36th Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, p. 610-615, 2021. DOI: <https://doi.org/10.1109/YAC53711.2021.9486582>.
- LIEW, F.; DELATTE, D.; TAKEISHI, N.; YAIRI, T. Recent developments in aerial robotics: a survey and prototypes overview. *ArXiv*, v. 1711.10085, 2017. DOI: <https://doi.org/10.48550/arXiv.1711.10085>.
- LILIENTHAL, A.; ZELL, A.; WANDEL, M.; WEIMAR, U. Sensing odour sources in indoor environments without a constant airflow by a mobile robot. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. Seoul, Korea, 2001. DOI: <https://doi.org/10.1109/robot.2001.933243>.
- LILIENTHAL, A.; DUCKETT, T. Building gas concentration gridmaps with a mobile robot. *Robotics and Autonomous Systems*, 48(1), p. 3–16. 2004. DOI: <https://doi.org/10.1016/j.robot.2004.05.002>.
- LILIENTHAL, A.; LOUTFI, A.; DUCKETT, T. Airborne Chemical Sensing with Mobile Robots. *Sensors*, 6(11), 1616–1678, 2006. DOI: <https://doi.org/10.3390/s6111616>.
- LILIENTHAL, A. J.; REGGENTE, M.; TRINCAVELLI, M.; BLANCO, J. L.; GONZALEZ, J. A statistical approach to gas distribution modelling with mobile robots - the kernel DM+V
-

algorithm. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems*. 2009. DOI: <https://doi.org/10.1109/iros.2009.5354304>.

LIMA, G. V. *Planejamento de Trajetórias para Quadricópteros em Tarefas de Perseguição*. Tese (Doutorado), Curso de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2019.

LOCHMATTER, T. *Bio-inspired and probabilistic algorithms for distributed odor source localization using mobile robots*. PhD Thesis, École Polytechnique Fédérale de Lausanne, Lausanne, 2010.

LUO, B.; MENG, Q-H.; WANG, J-Y.; MA, S-G. Simulate the aerodynamic olfactory effects of gas-sensitive UAVs: a numerical model and its parallel implementation. *Advances in Engineering Software*, v. 102, p. 123-133, 2016. DOI: <https://doi.org/10.1016/j.advengsoft.2016.10.001>.

LUUKKONEN, T. *Modelling and Control of Quadcopter*. Independent Research Project in Applied Mathematics, 2011.

MA, T.; LIU, S.; XIAO, H. Multirobot searching method of natural gas leakage sources on offshore platform using ant colony optimization. *International Journal of Advanced Robotic Systems*, 17(5), 2020. DOI: <https://doi.org/10.1177/1729881420959012>.

MAAG, B.; ZHOU, Z.; THIELE, L. A survey on sensor calibration in air pollution monitoring deployments. *IEEE Internet of Things Journal*, v. 5, n. 6, 2018. DOI: <https://doi.org/10.1109/jiot.2018.2853660>.

MACEDO, J.; MARQUES, L.; COSTA, E. A comparative study of bio-inspired odour source localisation strategies from the state-action perspective. *Sensors*, 19, 2231, 2019. <https://doi.org/10.3390/s19102231>.

MARQUES, L.; NUNES, U.; ALMEIDA, A. T. Cooperative odour field exploration with genetic algorithms. In *Proceedings of the 5th Portuguese Conference on Automatic Control (Controlo)*, Aveiro, p. 138-143, 2002.

MIAO, Y.; WANG, Y.; ZHANG, J. New strategies based on improved fruit fly optimization algorithm for unknown indoor odor source location. In *Proceedings of the 2020 IEEE International Conference on Real-time Computing and Robotics*. Asahikawa, Japan, 2020. DOI: <https://doi.org/10.1109/RCAR49640.2020.9303036>.

MISHRA, V. N.; DWIVEDI, R.; DAS, R. R. Classification of gases/odors using dynamic responses of thick film gas sensor array. *IEEE Sensors Journal*, v. 13, n. 12, p. 4924-4930, 2013. DOI: <https://doi.org/10.1109/JSEN.2013.2278459>.

MONROY, J.; HERNANDEZ-BENNETS, V.; FAN, H.; LILIENTHAL, A.; GONZALEZ-JIMENEZ, J. GADEN: A 3D Gas Dispersion Simulator for Mobile Robot Olfaction in Realistic Environments. *Sensors (Basel)*, 17(7):1479, 2017. DOI: <https://doi.org/10.3390/s17071479>.

NEUMANN, P.P. *Gas Source Localization and Gas Distribution Mapping with a Micro-Drone*. Dissertation. Universität Berlin, 2013.

NEUMANN, P. P.; HÜLLMANN, D.; BARTHOLMAI, M. Concept of a gas-sensitive nano aerial robot swarm for indoor air quality monitoring. *Materials Today: Proceedings*, v. 12, p. 470–473, 2019. DOI: <https://doi.org/10.1016/j.matpr.2019.03.151>.

NEUMANN, P. P.; HIRSCHBERGER, P.; BAURZHAN, Z.; TIEBE, C.; HOFMANN, M.; HULLMANN, D.; BARTHOLMAI, M. Indoor air quality monitoring using flying nanobots: design and experimental study. In *Proceedings of the IEEE International Symposium on Olfaction and Electronic Nose (ISOEN)*. Fukuoka, Japan, 2020. DOI: <https://doi.org/10.1109/ISOEN.2019.8823496>.

PANG, S.; FARRELL, J. A. Chemical plume source localization. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 36, n. 5, p. 1068-1080, 2006, DOI: <https://doi.org/10.1109/TSMCB.2006.874689>.

PETERSON, P. J. D.; AUJLA, A.; GRANT, K. H.; BRUNDLE, A. G.; THOMPSON, M. R.; VANDE HEY, J.; AND LEIGH, R. J. Practical use of metal oxide semiconductor gas sensors for measuring nitrogen dioxide and ozone in urban environments. *Sensors*, 17(7), 1653, 2017. DOI: <https://doi.org/10.3390/s17071653>.

PRABOWO, Y. A.; RANASINGHE, R.; DISSANAYAKE, G.; RIYANTO, B.; YULIARTO, B. A Bayesian approach for gas source localization in large indoor environments. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, p. 4432-4437, 2020. DOI: <https://doi.org/10.1109/IROS45743.2020.9341747>.

PREISS, J. A.; HONIG, W.; SUKHATME, G. S.; AYANIAN, N. CrazySwarm: a large nano-quadcopter swarm. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, p. 3299-3304, Singapore, 2017. DOI: <https://doi.org/10.1109/ICRA.2017.7989376>.

PURNAMADAJA, A. H.; RUSSELL, R. A. Pheromone communication in a robot swarm: necrophoric bee behaviour and its replication. *Robotica*, v. 23, n. 6, p. 731-742, 2005. DOI: <https://doi.org/10.1017/S0263574704001225>.

PYK, P.; BERMÚDEZ I BADIA, S.; BERNARDET, U.; KNÜSEL, P.; CARLSSON, M.; GU, J.; J. VERSCHURE, P. F. M. An artificial moth: chemical source localization using a robot based neuronal model of moth optomotor anemotactic search. *Autonomous Robots*, v. 20, n. 3, p. 197-213, 2006. DOI: <https://doi.org/10.1007/s10514-006-7101-4>.

REGGENTE, M.; LILIENTHAL, A. J. The 3D-Kernel DM+V/W algorithm: using wind information in three-dimensional gas distribution modelling with a mobile robot. In *Proceedings of the IEEE Sensors*. 2010. DOI: <https://doi.org/10.1109/icsens.2010.5690924>.

REHMAN, A. UR; BERMAK, A. Concentration estimation of industrial gases for electronic nose applications. In *Proceedings of the 30th International Conference on Microelectronics (ICM)*, 2018, p. 13-16, DOI: <https://doi.org/10.1109/ICM.2018.8704032>.

RODRÍGUEZ, J. D.; GÓMEZ-ULLATE, D.; MEJÍA-MONASTERIO, C. Limits on the performance of infotaxis under inaccurate modelling of the environment. *ArXiv*, v. 1408.1873, 2014. DOI: <https://doi.org/10.48550/arXiv.1408.1873>.

ROSSI, M.; BRUNELLI, D. Gas sensing on unmanned vehicles: challenges and opportunities. In *Proceedings of the New Generation of CAS (NGCAS)*. Genova, Italia, 2017. DOI: <https://doi.org/10.1109/NGCAS.2017.58>.

RUSSELL, R. A.; BAB-HADIASHAR, A.; SHEPHERD, R. L.; WALLACE, G. G. A comparison of reactive chemotaxis algorithms. *Robotics and Autonomous Systems*, v. 45, n. 2, p. 83-97, 2003. DOI: [https://doi.org/10.1016/S0921-8890\(03\)00120-9](https://doi.org/10.1016/S0921-8890(03)00120-9).

SCHMUKER, M.; BAHR, V.; HUERTA, R. Exploiting plume structure to decode gas source distance using metal-oxide gas sensors. *Sensors and Actuators B: Chemical*, v. 235, n. 1, p. 636-646, 2016. DOI: <https://doi.org/10.1016/j.snb.2016.05.098>.

SCOTT, D. W. Multivariate density estimation: theory, practice, and visualization. John Wiley & Sons, New York, Chicester, 1992.

SGP30. *Datasheet SGP30 Indoor Air Quality Sensor for TVOC and CO₂eq Measurements*. Disponível em: https://sensirion.com/media/documents/984E0DD5/61644B8B/Sensirion_Gas_Sensors_Datasheet_SGP30.pdf. Acesso em: 10 de março de 2021.

SHEN, X.; YUAN, J.; SHAN, Y. A novel plume tracking method in partial 3D diffusive environments using multi-sensor fusion. *Expert Systems with Applications*, v. 178, n. 114993. 2021. DOI: <https://doi.org/10.1016/j.eswa.2021.114993>.

SHIGAKI, S.; FIKRI, M.; KURABAYASHI, D. Design and experimental evaluation of an odor sensing method for a pocket-sized quadcopter. *Sensors*, 18(11), 3720, 2018. DOI: <https://doi.org/10.3390/s18113720>.

VERGASSOLA, M.; VILLERMAUX, E.; SHRAIMAN, B. I. Infotaxis as a strategy for searching without gradients. *Nature*, v. 445, n. 7126, p. 406-409, 2007. DOI: <https://doi.org/10.1038/nature05464>.

VILLA, T.F.; SALIMI, F.; MORTON, K.; MORAWSKA, L.; GONZALEZ, F. Development and validation of a UAV based system for air pollution measurements. *Sensors*, 16 (12), 2202. 2016. DOI: <https://doi.org/10.3390/s16122202>.

VUKA, M. *A Gaussian Regression Based Exploration Strategy for Gas Source Localization*. PhD Thesis, Politecnico di Milano, Scuola di Ingegneria Industriale e dell'Informazione, 2016.

WANG, L.; PANG, S. An implementation of the adaptive neuro-fuzzy inference system (ANFIS) for odor source localization. In *Proceedings of the 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2020. DOI: <https://doi.org/10.1109/iro45743.2020.9341688>.

WANG, L.; PANG, S.; LI, J. Learn to trace odors: autonomous odor source localization via deep learning methods. In *Proceedings of the 20th IEEE International Conference on Machine Learning and Applications (ICMLA)*, p. 1429-1436, 2021. DOI: <https://doi.org/10.1109/ICMLA52953.2021.00230>.

YAMAMOTO, A.; BILGERA, C.; SAWANO, M.; MATSUKURA, H.; SAWADA, N.; LEOW, C.-S.; ISHIDA, H. Application of sequence input and output long short-term memory neural networks for autonomous gas source localization in an outdoor environment. In *Proceedings of the IEEE International Symposium on Olfaction and Electronic Nose (ISOEN)*. 2019. DOI: <https://doi.org/10.1109/isoen.2019.8823160>.

ZHAO, Y.; CHEN, B.; WANG, X.; ZHU, Z.; WANG, Y.; CHENG, G.; WANG, R.; WANG, R.; HE, M.; LIU, Y. A deep reinforcement learning based searching method for source localization. *Information Sciences*, v. 588, p. 67-81, 2022. DOI: <https://doi.org/10.1016/j.ins.2021.12.041>.
