



Análise do Desempenho Energético em Frotas de Drones Autônomos

*Fernando dos Reis Santos Filho Luiz Fernando Bittencourt
Fabíola M. C. de Oliveira*

Relatório Técnico - IC-PFG-24-24
Projeto Final de Graduação
2024 - Dezembro

UNIVERSIDADE ESTADUAL DE CAMPINAS
INSTITUTO DE COMPUTAÇÃO

The contents of this report are the sole responsibility of the authors.
O conteúdo deste relatório é de única responsabilidade dos autores.

Análise do Desempenho Energético em Frotas de Drones Autônomos

Fernando dos R. S. Filho Luiz Fernando Bittencourt
Fabíola M. C. de Oliveira

Resumo

Ao modelar e simular estratégias anticolidões em um cenário de alta densidade de drones, é vital considerar o consumo de energia para garantir um planejamento de voo eficiente. Este trabalho realiza uma análise do desempenho energético em frotas de drones autônomos em cenários de entrega urbana, avaliando estratégias de detecção e evasão de colisões aplicadas a diferentes modelos de consumo de energia. Essa análise consiste na comparação de diferentes métricas de desempenho como taxas de colisão, taxas de falhas na bateria e na combinação de ambas em uma taxa total de falhas. Os resultados obtidos indicam uma relação inversa entre a taxa de colisão e a taxa de falhas na bateria. Por fim, este trabalho também destaca a importância do estudo e pesquisa de modelos empíricos de consumo energético, além do cuidado na escolha dos modelos e calibração dos seus parâmetros para garantir simulações de drones autônomos mais realistas e precisas.

1 Introdução

Nos últimos anos, os Veículos Aéreos Não Tripulados (VANTS) ou drones vêm desempenhando um papel crescente em aplicações comerciais, como uma forma de entrega de bens de consumo. Com sua capacidade de entrega rápida, redução de custos operacionais e diminuição de emissão de gases de efeito estufa, os drones são uma solução ideal para os desafios logísticos urbanos. Os Drones são mais leves, baratos e consomem menos energia por entrega do que um caminhão, sendo altamente eficientes para entrega de cargas leves a curtas distâncias. [4] Contudo, atender a demanda de entregas de uma cidade moderna requer a utilização de drones em grande escala o que gera o desafio de gerenciamento eficiente do consumo energético e a prevenção de colisões em cenários de alta densidade de drones.

O desempenho energético é particularmente crítico para drones, cuja autonomia depende diretamente das características de suas baterias e do consumo durante o voo. Portanto, é essencial ser capaz de ter uma estimativa precisa do consumo de energia dos drones ao longo do voo para garantir um planejamento de voo eficiente. Dentre os estudos de modelos de consumo de energia em drones é possível encontrar inúmeros modelos teorizados. Os mais simples, apenas consideram um modelo indireto de consumo de energia, ao adotarem um limite fixo no tempo de voo ou alcance. Outros modelos mais complexos e dinâmicos consideram as forças físicas fundamentais envolvidas no voo ou se baseiam em dados empíricos

medidos em campo. Alguns desses modelos de consumo de energia de drones são bastante simples com apenas alguns parâmetros, enquanto outros são muito complexos compostos por múltiplos componentes interdependentes que fornecem representações detalhadas das forças de voo e design de drones. [4] Assim, para garantir um gerenciamento eficiente e preciso do consumo energético é essencial compreender as diferenças nos resultados desses modelos mesmo quando aplicados para a mesma operação de delivery, resultando em autonomias e alcances divergentes.

Além do gerenciamento energético, a implementação de serviços de entrega com grandes frotas de drones introduz o desafio de planejamento de voo para evitar colisões. Em ambientes urbanos, drones enfrentam riscos de colisão com edifícios, árvores, pássaros, aeronaves e outros drones [2]. Estratégias eficazes de evasão de colisão são essenciais para garantir a segurança das operações e a viabilidade dos serviços em grande escala. Técnicas que incluem abordagens geométricas, decisões autônomas baseadas em sensores e técnicas de aprendizado de máquina têm sido propostas na literatura, cada uma com diferentes graus de complexidade. Logo, a escolha da técnica ideal deve equilibrar a prevenção de colisões com a eficiência energética.

Este trabalho se propõe a analisar o desempenho energético de frotas de drones autônomos comparando o comportamento de dois modelos de consumo energético: D'Andrea [5] e Tseng [6] ao serem executados em técnicas geométricas não cooperativas de detecção e evasão de colisões. Para isso, será utilizado uma versão adaptada do software UTSim [2] [3] para realizar simulações 3D de cenários de emergência onde cada drone está em um nível crítico de bateria e eles não se comunicam e cooperam entre si na evasão de colisão. Com o resultado das simulações será possível gerar e avaliar métricas como como taxas de colisão, taxas de falhas na bateria e a combinação destas em uma taxa total de falhas. Enquanto estratégias de planejamento de voo livre de colisões e falhas de bateria não forem aperfeiçoadas, um sistema de entrega autônomo em alta densidade urbana permanecerá inviável. Portanto, antes de avaliar sistemas complexos de planejamento, como os baseados em aprendizado profundo (deep learning), é essencial compreender plenamente os fatores que determinam o sucesso de abordagens mais simples, como as estratégias geométricas [2]. Este estudo visa aprofundar o entendimento das limitações energéticas e suas consequências na detecção e evasão de colisão envolvidas em métodos não cooperativos, oferecendo uma base para futuras análises e melhorias em estratégias mais sofisticadas.

Esse trabalho será estruturado da seguinte forma: no Capítulo 2 será apresentado os diferentes tipos de baterias e conceitos básicos de sua construção e impactos no voo de um drone. Nos Capítulos 3 e 4 serão apresentados uma revisão da literatura, abordando os trabalhos relacionados e estudos dos diferentes modelos de consumo energético e técnicas de evasão de colisão. O Capítulo 5 descreve a metodologia utilizada, as configurações e cenários das simulações. Os resultados serão discutidos no Capítulo 6. Por fim, no Capítulo 7, são discutidas as principais conclusões do estudo apresentado e as perspectivas para estudos e trabalhos futuros.

2 Conceitos Básicos

Para melhor compreensão do impacto energético dos modelos de consumo apresentados na literatura, é necessário compreender o funcionamento e a modelagem das baterias mais utilizadas em drones de acordo com as expectativas de performance desejadas. Portanto, a seção 2.1 irá introduzir os principais tipos de baterias utilizadas no mercado em drones comerciais e suas diferenças. A seção 2.2 aprofunda a explicação sobre os parâmetros operacionais, enquanto a seção 2.3 apresenta as fórmulas utilizadas nas simulações para modelar as baterias.

2.1 Principais tipos de baterias utilizadas em drones comerciais

As baterias são componentes essenciais para o funcionamento dos drones autônomos ou não, fornecendo energia para motores, sistemas eletrônicos embarcados, sensores e comunicação. Elas desempenham um papel crucial na definição da autonomia de voo, sendo diretamente influenciada pelas características químicas internas da bateria e pela eficiência energética dos drones. Assim, o entendimento do funcionamento das baterias e a escolha do tipo ideal de bateria é essencial para atender ao consumo e exigências de desempenho de voo em aplicações como o uso de frota de drones autônomos no delivery de bens de consumo em cenários urbanos.

O funcionamento das baterias e acumuladores baseia-se em reações químicas complexas, nas quais elementos químicos específicos participam ativamente para converter a energia química armazenada em energia elétrica utilizável. Assim, as baterias podem ser definidas como fontes químicas de corrente elétrica, cuja operação depende de um conjunto de substâncias ativas e eletrólitos, encapsulados em células que contêm eletrodos positivos e negativos em um invólucro selado [7]. Atualmente existem três principais tipos de baterias amplamente utilizadas e estudadas para uso em drones comerciais: baterias de íons de lítio (Lí-ion), baterias de polímero de lítio (LiPo) e, mais recentemente, células de combustível à base de hidrogênio [7] [8].

As baterias Lí-ion são conhecidas por sua alta densidade energética, o que significa que podem armazenar uma grande quantidade de energia em um volume relativamente pequeno. Sua faixa de tensão operacional está entre 2.5 V a 4.1 V por célula, enquanto sua tensão nominal é de 3.6 V. Comparada com as baterias sua taxa de descarga é inferior, alcançando até 5C, embora não seja recomendado manter a faixa de 1 a 2C. Esse tipo de bateria é amplamente utilizado devido à sua confiabilidade e longa vida útil, que pode variar entre 500 e 1000 ciclos de carga e descarga. No entanto, as Lí-ion apresentam menor resistência mecânica, um peso maior e menores taxas de descarga em comparação com as LiPo. [7]

As baterias LiPo são uma evolução das Lí-ion, substituindo os eletrólitos líquidos por polímeros sólidos ou em forma de gel. Essa mudança confere às LiPo maior flexibilidade estrutural, permitindo designs ultraleves e moldáveis para drones menores e mais ágeis, além de maior resistência em casos de curto circuito ou sobrecarga. Com uma tensão nominal de 3.7 V por célula e taxas de descarga que podem chegar a 30C, as LiPo são ideais para drones que realizam manobras intensas e rápidas. [7]

As células de combustível de hidrogênio representam uma alternativa promissora para

drones de longa autonomia e alta capacidade de carga. Essas baterias funcionam por meio de uma reação eletroquímica entre hidrogênio e oxigênio, gerando energia elétrica e água como subproduto. [8] Com densidade energética significativamente maior do que as baterias de Lí-ion ou LiPo, as células de combustível permitem tempos de voo muito mais longos. Contudo, sua implementação enfrenta desafios como o custo elevado, maior peso e complexidade na infraestrutura de reabastecimento. Essas características as tornam mais indicadas para drones maiores e para aplicações industriais ou agrícolas.

2.2 Funcionamento das baterias

As baterias consistem em conjuntos de duas ou mais células voltaicas do mesmo tipo, projetadas para fornecer uma corrente elétrica. A construção físico-química das baterias define os valores para a sua tensão, capacidade, taxa de descarga, temperatura de operação e vida útil. [7] A tensão de uma bateria é determinada pela diferença de potencial elétrico entre seus terminais. As baterias a base de lítio, como Lí-ion e LiPo, possuem uma tensão nominal de 3.6V e 3.7V, respectivamente, e a sua configuração de agregação de células em série, cujo número de células agregadas pelo valor "S" (3S, 4S, 6S, etc.), aumenta proporcionalmente a tensão nominal total da bateria. As baterias mais comuns de serem utilizadas em drones para fins comerciais são de baterias LiPo de 6S, possuindo uma tensão nominal total de 22.2V.

A capacidade de uma bateria, medida em miliampere-hora (mAh) ou ampere-hora (Ah), é a quantidade de carga elétrica transferida por uma corrente estável de um ampère durante uma hora. Essa unidade é comumente utilizada para determinar o tempo de duração ou a quantidade de carga de uma bateria sujeita a uma determinada corrente. Assim, quanto maior a capacidade, maior a autonomia e o alcance do voo do drone. No entanto, baterias de alta capacidade tendem a ser mais pesadas o que, por sua vez, aumenta o consumo de energia dos drones ao exigirem maior potência dos motores para sustentar seu peso durante o voo. Essa relação entre capacidade e peso cria um equilíbrio delicado ao se considerar na hora de escolher uma bateria ideal para maximizar alcance e tempo de voo.

A taxa de descarga, indicada pelo C-rating, o quão rápido uma bateria pode ser carregada ou descarregada em relação à sua capacidade. Por exemplo, uma bateria com C-rating de 25C pode descarregar até 25 vezes a sua capacidade nominal em corrente instantânea, tornando-a ideal para drones que requerem alta potência em situações de pico. Apesar disso, descarregar uma bateria no limite da taxa de descarga por longos períodos de tempo pode gerar um aquecimento elevado, reduzindo a vida útil da bateria e, em casos extremos, provocando falhas graves durante o voo ou até mesmo incêndios.

Cada tipo de bateria possui uma faixa de temperatura ideal para operação eficiente. As baterias de Lí-ion e LiPo normalmente operam entre -40°C e 65°C [7]. Assim como para a taxa de descarga, operar bateria em altas temperaturas por tempo prolongado pode causar degradação acelerada da bateria. O uso de sistemas de gerenciamento de bateria (BMS) para monitorar o uso da bateria e garantir a segurança durante o seu funcionamento [7].

2.3 Modelando uma bateria

Uma vez conhecendo os principais tipos de baterias e seus parâmetros operacionais, é possível utilizar-se das relações físicas entre esses parâmetros para modelar o comportamento das baterias de drones nas simulações realizadas. A tabela a seguir apresenta uma notação unificada para garantir a identificação dos parâmetros apresentados nas fórmulas de modelagem e consumo energético das baterias.

Parâmetro	Descrição	Unidade
V	Tensão nominal	Volts (V)
C	Capacidade	Ampere-hora (Ah)
D	Taxa de descarga	[Sem unidade]
I	Corrente	Ampere (A)
E_{total}	Energia total armazenada	Watt-hora (Wh)
E_{pm}	Energia consumida por metro	Joules por metro (J/m)
P	Potência consumida	Watts (W)
P_{avio}	Potência necessária para o hardware	Watts (W)
t	Tempo de voo	Horas (h)
m	Massa total	Quilogramas (kg)
v_a	Velocidade aérea	Metros por segundo (m/s)
g	Aceleração gravitacional	Metros por segundo ao quadrado (m/s ²)
r	Relação sustentação-arrasto	[Sem unidade]
η	Eficiência de transferência de energia	[Sem unidade]
φ	Relação entre velocidade do vento e velocidade aérea	[Sem unidade]

Tabela 1: Parâmetros utilizados para modelagem de baterias.

Uma forma de medir a autonomia total de uma bateria é através da sua energia total. Com o valor da energia total disponível pela bateria é possível calcular o tempo máximo de voo dos drones:

$$E_{total} = V \times C = V \times I \times t_{total} \quad (1)$$

Além da energia total, outro fator limitante para o sucesso do voo dos drones é a sua corrente máxima:

$$I_{m\acute{a}x} = C \times D \quad (2)$$

Como mencionado anteriormente, a taxa de descarga (C-rating) determina quantas vezes a sua própria capacidade interna uma bateria é capaz de oferecer em corrente máxima. Drones que exigem manobras bruscas e picos de energia irão demandar uma bateria com uma alta taxa de descarga e, conseqüentemente, irão esgotar a sua bateria mais rápido. Assim, se a potência instantânea consumida pelos motores dos drones para manter voo estável e por todos os seus componentes eletrônicos:

$$I = \frac{P + P_{avio}}{V} \quad (3)$$

for maior que a corrente máxima produzida pela bateria isso acarretará em um superaquecimento, levando à falhas na produção de energia e até mesmo um incêndio na bateria.

3 Modelos de Consumo Energético

A implementação da modelagem das baterias, apresentada no capítulo anterior, é crucial para garantir que as simulações sejam capazes de calcular com precisão o comportamento das baterias. Assim, o próximo passo é garantir uma estimativa confiável do cálculo das potências consumidas pelos drones ao longo dos seus voos.

Contudo, estimar o consumo de energia dos drones é um desafio que envolve inúmeras variáveis como a complexidade das forças físicas envolvidas no voo, condições climáticas até ao formato e construção dos drones. Como resultado dessa complexidade, é possível encontrar na literatura uma ampla variedade de modelos de consumo de energia pesquisados e publicados. A pesquisa atual não chegou a um consenso sobre os melhores modelos de consumo [4] [5] [6]. Esse capítulo irá apresentar esses desafios, as principais categorias dos diferentes modelos apresentados na literatura e os modelos escolhidos para serem avaliados neste trabalho.

3.1 Desafios na implementação

O consumo energético de drones é influenciado por uma variedade de fatores que podem ser agrupados em quatro categorias principais: design do drone, dinâmica de voo, ambiente e operações de entrega. No design do drone, características como peso, tamanho, número de motores, eficiência de transferência de energia, capacidade da bateria, relação sustentação-arrasto são determinantes para o consumo de energia. A dinâmica de voo engloba aspectos como velocidade de deslocamento, tipo de movimento (decolagem, pouso, voo horizontal, etc.) e acelerações. No ambiente, fatores como densidade do ar, gravidade, condições climáticas (vento, neve, chuva) e temperatura influenciam diretamente a eficiência do drone. Finalmente, as operações de entrega consideram variáveis como o peso da carga, número de entregas por viagem e o modo de entrega utilizado [4].

Esses fatores interagem de forma dinâmica e interdependente. Por exemplo, o peso da carga útil e da bateria afetam o consumo de energia, que por sua vez influencia o alcance operacional dos drones. A velocidade aérea (velocidade dos drones em relação ao ar) também exerce um impacto bidirecional: enquanto velocidades mais altas podem aumentar o consumo devido ao arrasto, elas podem reduzir o tempo de voo total e, conseqüentemente, o gasto energético. Esses aspectos complexos tornam a estimativa precisa do consumo energético desafiador, especialmente em operações que envolvem diferentes modos de voo e condições ambientais variáveis.

Portanto, modelar o consumo energético de drones requer o entendimento detalhado de como esses fatores interagem e afetam o desempenho. Além disso, a incerteza nos parâmetros e a necessidade de adaptação a condições específicas de cada missão tornam esse processo ainda mais exigente, destacando a importância de modelos robustos e bem calibrados.

3.2 Categorias de modelos de consumo de energia

Dada a variedade de modelos apresentados na literatura, eles podem ser classificados em três principais categorias: modelos integrados, baseados em componentes e modelos de re-

gressão [4]. Os modelos integrados são os modelos mais simples e que utilizam a relação sustentação-arrasto para simplificar as forças aerodinâmicas em uma única equação. Modelos integrados, como o proposto por D’Andrea [4] [5], por serem mais simples, esses modelos são úteis para estimativas gerais do consumo de energia, mas, em contrapartida, podem subestimar a complexidade de missões reais de drones utilizados em delivery.

Já os modelos baseados em componentes separam as contribuições individuais das forças físicas fundamentais envolvidas no voo, como as envolvidas na sustentação e arrasto. Esses modelos possuem vários graus de detalhes, se tornando cada vez mais complexos. Modelos como os de Kirchstein e Stolaroff [4], capturam nuances específicas do projeto e operação dos drones, mas são muito mais complexos em sua modelagem.

Por fim, os modelos de regressão são baseados em dados reais experimentais. Modelos como o de Tseng [4] [6], ajustam equações não-lineares aos dados de consumo energético medidos em voo reais, permitindo maior precisão no cálculo do consumo energético. Porém esses modelos estão limitados às condições específicas e limitadas pela cenário de teste no qual os dados foram capturados. Assim, ao contrário dos outros tipos de modelo, esse modelo não é ideal para generalizar um o cálculo do consumo de energia para diferentes tipos de drones e cenários de voo.

3.3 Modelos avaliados: D’Andrea e Tseng

Para poder avaliar a diferenças entre os modelos propostos na literatura, foram selecionados um modelo integrado (D’Andrea) [4] [5] e um modelo (Tseng) [4] [6] para comparar as abordagens de um modelo generalista com um modelo empírico e especificista. O modelo proposto por D’Andrea é um modelo conhecido por seu cálculo simplificado e capacidade de generalização para diferentes tipos de drones executados em diferentes cenários. Como um modelo integrado, ele utiliza a relação sustentação-arrasto ($r = 3$) como parâmetro para unificar as principais forças físicas atuantes durante o voo. O modelo D’Andrea calcula a energia por metro consumida pelos drones de acordo com a fórmula:

$$E_{\text{pm}} = \frac{1}{1 - \varphi} \left(\frac{gm_{\text{total}}}{\eta \times r} + \frac{P_{\text{avio}}}{v_a} \right) \quad (4)$$

Para obter a potência instantânea consumida pelos drones basta multiplicar a energia por metro pela velocidade aérea (v_a). A fórmula do modelo D’Andrea também considera o impacto do vento, ajustando o fator φ , definido como a razão entre a velocidade do vento e a velocidade aérea dos drones.

Diferente dos modelos integrados, modelos empíricos, como o Tseng, utilizam uma abordagem de regressão não-linear para estimar o consumo energético dos drones durante o voo através de dados reais coletados em campo. O modelo Tseng considera inúmeras variáveis como velocidade horizontal e vertical, aceleração, massa do drones, bateria e carga, velocidade aérea do drone (v_a), dentre outros. Em cenários de voo sem vento, o modelo se reduz à seguinte fórmula:

$$P = \beta_1 v_a + \beta_7 m_{\text{bateria}} + \beta_9 \quad (5)$$

Foram coletados dados de voos usando os drones 3DR Solo (pesando 2kg), com pequenas cargas de 0 kg, 0.25 kg e 0.5 kg, e o drone DJI Matrice 100 (pesando 2.8 kg) com pequenas cargas de 0 kg, 0.3 kg e 0.6 kg [4] [6]. A fórmula de regressão da energia por metro do drone DJI Matrice 100 para um voo sem vento e com uma velocidade de no máximo 5 m/s é:

$$E_{\text{pm}} = \frac{P}{v_a} = -1.529 + \frac{0.220m_{\text{bateria}} + 433.9}{v_a} \quad (6)$$

Já para o drone 3DR Solo a regressão linear fica na forma:

$$E_{\text{pm}} = -2.595 + \frac{0.197m_{\text{bateria}} + 251.7}{v_a} \quad (7)$$

4 Detecção e Evasão de Colisão

Além da eficiência energética, a detecção e evasão de colisões com objetos estacionários ou móveis é fundamental para o sucesso da implantação de um serviço de entregas por drones. Árvores, prédios, montanhas ou sinalizações urbanas são exemplos de objetos estacionários, enquanto pássaros e outras aeronaves são objetos móveis que geram interferência no espaço aéreo e possíveis objetos de colisões [2]. Tais colisões podem ter consequências graves tanto em termos materiais como colocar em risco a segurança e a vida dos indivíduos. Ter a capacidade de detecção e evasão de colisão não é apenas uma questão de eficiência no planejamento de voo, mas também uma questão de segurança.

Existem diferentes classificações para estratégias anticolidões, mas esse processo é normalmente classificado em três etapas: detecção de obstáculos, previsão de colisões e a evasão propriamente dita [2]. Um drone analisa o seu ambiente através de múltiplos sensores como sensores ultrassônicos, câmeras e LiDARs, realizando a detecção de objetos de forma individual ou colaborativa através do compartilhamento de dados. Uma vez detectado um obstáculo, os métodos de previsão de colisão calculam a probabilidade de impacto, seja através de métodos determinísticos ou não-determinísticos. Métodos determinísticos usam equações ou algoritmos definidos previamente de forma que, dado uma entrada de dados, ele produzirá sempre o mesmo resultado. Os métodos não-determinísticos, por sua vez, são baseados em probabilidade ou em técnicas de machine learning que estão constantemente aprendendo com o movimento do drone e dos obstáculos para calcular as trajetórias e prever colisões [2]. Assim, esse trabalho visa comparar as técnicas DoNothing [2], Seo et al. [9], SingleDrone [2] e MultiDrone [2], avaliando o seu desempenho em cenários simulados de alta densidade de drones.

A abordagem DoNothing simplesmente não executa detecção e evasão de colisão, sendo a linha de base para avaliar o desempenho das demais técnicas. A técnica proposta por Seo et al. [9] é uma técnica geométrica de prevenção de colisões, aplicável tanto a drones individuais quanto a enxames. Ela utiliza um envelope de prevenção que considera a taxa angular do drone e os limites do alcance de detecção de objetos para avaliar a viabilidade de desvios. Além disso, propõe uma estratégia que lida com múltiplos obstáculos, definindo um ângulo

de desvio em relação a todos os objetos que representam risco de colisão para um drone específico. Apesar de ser uma abordagem promissora, o método apresenta limitações críticas. Ele assume velocidades e direções constantes tanto para drones quanto para obstáculos, realiza a avaliação em um cenário bidimensional, onde drones e obstáculos operam na mesma altitude, e limita a simulação a um máximo de dois drones [2]. A técnica SingleDrone [2] realiza desvios individuais de rota para evitar colisões, considerando o primeiro obstáculo que entra em rota de colisão com o drone. O desvio é feito com o menor ângulo possível, minimizando o gasto energético durante a manobra. Outra característica do SingleDrone é que, ao detectar uma possível colisão, o drone reduz sua velocidade inicial máxima pela metade, diminuindo a probabilidade de impactos e otimizando o consumo energético. Já a técnica MultiDrone [2] leva em conta todos os obstáculos em rota de colisão simultaneamente, priorizando desvios que evitem múltiplas colisões. Inicialmente, ela calcula o menor ângulo de desvio para cada obstáculo, mas escolhe o maior entre esses ângulos, garantindo que o drone esteja seguro contra todos os riscos detectados. Caso obstáculos adicionais ainda apresentem risco após o desvio inicial, o drone realiza novos ajustes, priorizando o obstáculo mais próximo. Diferentemente do SingleDrone, o MultiDrone mantém sua velocidade máxima mesmo após detectar uma colisão, otimizando a eficiência em cenários com maior densidade de drones.

5 Metodologia

Nas próximas seções será apresentado o simulador utilizado e suas configurações, os planos de voo e as estratégias de evasão de colisão simuladas e as métricas consideradas para a análise.

5.1 O simulador e suas configurações

As simulações foram realizadas em ambiente Unity através de uma versão modificada do simulador UTSim, o FluteSim [2] [3]. Esse simulador foi projetado para executar simulações 3D de drones e avaliar a performance dos algoritmos de evasão de colisão em uma situação de alta densidade de drones. O FluteSim já possuía os modelos dos drones e da cidade no qual a frota de drones iria simular as entregas. Porém, foi necessário modificações no modelo do drone e o desenvolvimento do modelo da bateria para considerar o consumo energético na simulação.

O FluteSim simulava um drone de 2 m x 2 m x 0.5 m com uma velocidade máxima de 20 m/s, um raio de segurança de 30 m e um raio de detecção de 100 m. Originalmente o peso não era considerado na simulação [2]. Porém, para haver uma padronização e consistência nas análises do consumo energético, foram feitas alterações no modelo do drone do FluteSim para que ele estivesse de acordo com os parâmetros do drone utilizado pelo modelo Tseng [4]. Portanto, foi adicionado o peso de 2.8 kg para o modelo do drone (2.2 kg da estrutura e 0.6 kg da bateria do drone), sua velocidade máxima foi limitada a 5 m/s e foi implementado as funções que calculam o consumo energético tanto do modelo D’Andrea quanto para o Tseng.

Uma vez modelado o drone individual com sua respectiva bateria, o simulador também modela a área de voo das entregas. Como representado na figura 1, a área de voo simulada foi configurada como uma grade de 1 km x 1 km, contendo 100 centros de distribuição (representados pelos círculos laranjas) dispostos uniformemente a cada 40 metros, servindo como pontos de decolagem e pouso para os drones. Os drones realizam as entregas até seus destinos que estão distribuídos em uma área de 0.81 km² (representada pela área azul), garantindo uma distância segura de no mínimo 50 m entre todos os centros de distribuição. Os drones podem voar livremente em diferentes altitudes, latitudes e longitudes, sem rotas aéreas predefinidas, permitindo maior flexibilidade no planejamento de voo. A configuração dessa área de voo simula um bairro com alta densidade de pequenos vendedores, como restaurantes, sendo ideal para simular entregas urbanas densas. [4]

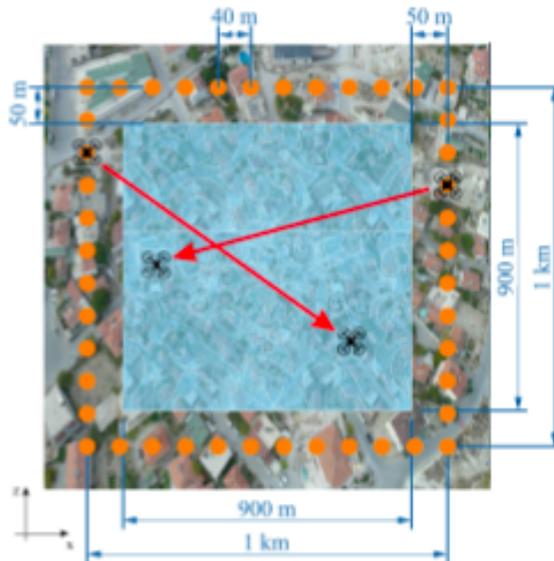


Figura 1: Vista superior da área de voo simulada.

5.2 Planos de voo e métricas avaliadas

Uma vez tendo o simulador configurado com os seus parâmetros operacionais e o de suas baterias, padronizados aos parâmetros utilizados nos experimentos de Tseng, e a área de voo estabelecida, foram planejados diferentes planos de voos para avaliar o desempenho energético e a eficiência da evasão de colisões de cada cenário. Serão executados 16 planos de voo, pareando uma técnica de evasão de colisão a um modelo de consumo de energia, sendo executados uma vez com uma taxa de chegada de 6 drones por minuto e outra de 12 drones por minuto. Os drones serão executados com apenas 20% de suas baterias para simular com que esses planos de voos sejam os últimos depois que os drones realizaram inúmeras entregas e sua bateria já está baixa. Assim, será possível analisar a eficácia das técnicas de evasão de colisão dentro e dos modelos de consumo de energia em uma situação

crítica. Para garantir uma relevância estatística, cada plano de voo foi executado 26 vezes, reportando a média dos dados capturados junto ao intervalo de 95% de confiança.

Para avaliar o desempenho dos planos de voos testados, foram utilizadas três métricas. A taxa de colisão representa o percentual de drones que falharam na evasão de colisão e colidiram durante o voo, enquanto a taxa de falhas energéticas representa o percentual de drones que falharam devido à descarga completa da bateria. A combinação destes dois fatores foi representada na taxa total de falhas, englobando a proporção total de incidentes críticos durante o voo.

Os dados coletados dessas métricas foram organizados e estruturados em gráficos, permitindo a comparação entre as diferentes estratégias de evasão de colisão e modelos de consumo energético para cada taxa de chegada de drones. A análise foi realizada com o objetivo de identificar padrões de desempenho, limitações e vantagens de cada abordagem, facilitando a interpretação dos resultados e a formulação de recomendações para trabalhos futuros baseados nas condições simuladas.

6 Resultados

Essa seção irá apresentar os resultados dos planos de voo, comparando o comportamento da combinação de cada modelo de consumo energético com uma técnica de evasão de colisão executada em cenários de média e alta densidade de drones.

6.1 Comparação entre os Modelos de Consumo Energético

Os resultados do experimento estão condizentes com o teorizado que o modelo Tseng, um modelo especificista, teria um consumo maior do que o modelo D'Andrea, um modelo generalista, passível de subestimar o consumo energético. Utilizando o cenário apresentado na metodologia, o drone DJI Matrice 100 com uma bateria de 0,6 kg voando a 5 m/s em um ambiente sem vento, teria um consumo de energia de aproximadamente 85.3 J/m ou 426.4 W, de acordo com o modelo Tseng (fórmula 6). Já o modelo D'Andrea (fórmula 4), o mesmo drone com uma massa total de 3.4 kg (2.2 kg de estrutura, 0.6 kg de bateria e 0.6 kg de carga útil) aplicado a uma aceleração da gravidade de 9.81 m/s^2 , fator sustentação-arrasto de 3 e um bateria de 95% de eficiência para alimentar 100 W de eletrônicos, daria um consumo de 31.7 J/m ou 158.5 W. Isso representa um aumento de aproximadamente 170% no consumo de energia do modelo Tseng para o D'Andrea, considerando o mesmo drone. Essa diferença pode claramente ser vista nos gráficos gerados pelos experimentos.

6.2 Taxa de falha na bateria

Pelas figuras 2 e figuras 3 é possível avaliar a relação nas falhas de bateria tanto entre os modelos de consumo energético quanto entre as técnicas de evasão de colisão. É possível visualizar de forma empírica a discrepância entre o consumo energético para ambos os modelos, para as técnicas SingleDrone e MultiDrone o aumento da porcentagem de falhas nas baterias foi de entre 1,7 a 2 vezes. No caso da técnica do SeoKimKimTsourdos o aumento foi ainda mais significativo. O resultado matematicamente irrisório das falhas

ocorridas ao se utilizar a técnica DoNothing se dá pelo fato de que, quando o drone não gasta tempo e energia desviando de colisões, ou o drone é bem sucedido no seu plano de voo ou ele entra em uma colisão. Diante da grande quantidade de falhas de baterias nos drones que utilizaram técnicas de evasão de colisão é possível concluir que esses planos de voo não possuem um bom desempenho energético.

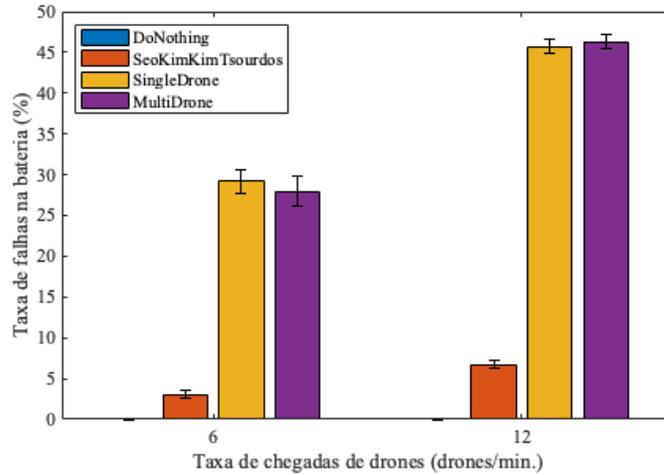


Figura 2: Taxa de falhas na bateria no modelo D'Andrea

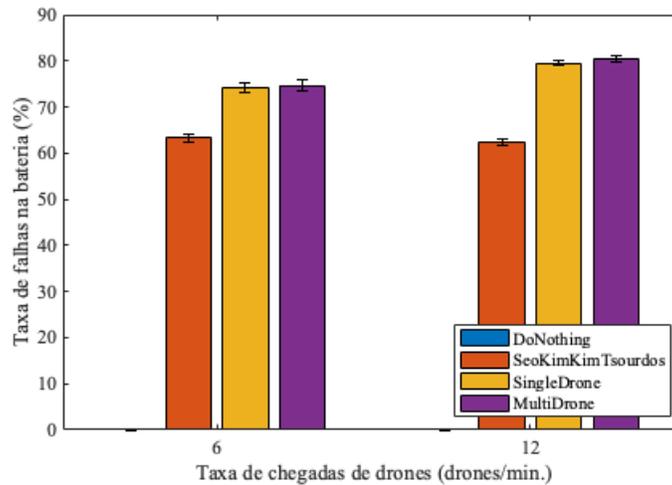


Figura 3: Taxa de falhas na bateria no modelo Tseng

6.3 Taxas de colisão

As taxas de colisões possuem um comportamento inverso ao das taxas de falhas nas baterias. Quanto mais tempo de voo um drone tem, mais sujeito a colisões ele está, o que demonstra o fato de o modelo D'Andrea possuir taxas de colisões maiores que o modelo Tseng em todas

as técnicas de evasão de colisão. Analisando o comportamento de cada técnica dentro de um mesmo modelo de consumo energético, técnicas que exigem mais desvios para evitar colisões, como o MultiDrone, apresentam menores taxas de colisão, mas, em contrapartida, resultam em maior consumo energético, aumentando a probabilidade de falhas na bateria. Já no caso do DoNothing quase não há falhas energéticas, mas taxas de colisão extremamente altas.

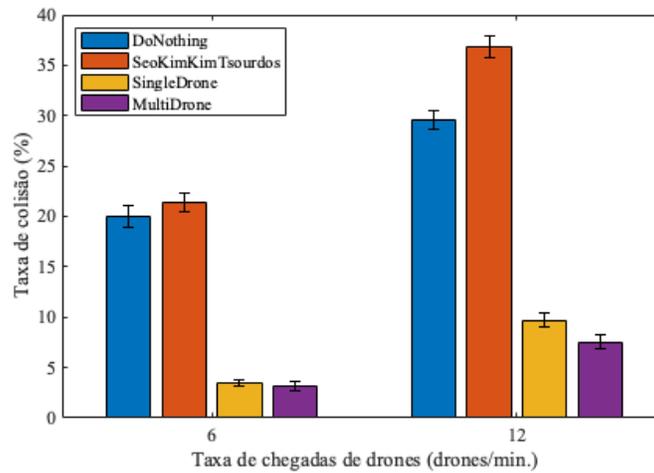


Figura 4: Taxa de colisões no modelo D'Andrea

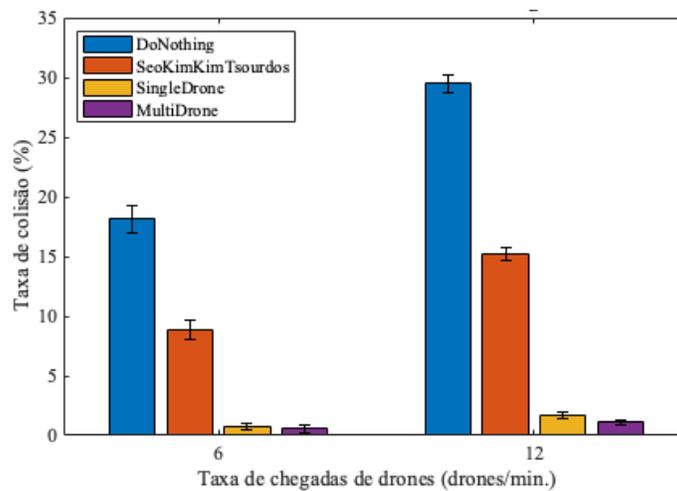


Figura 5: Taxa de colisões no modelo Tseng

6.4 Taxa de total de falhas

Ao unificar a taxa de colisão e as falhas causadas por insuficiência energética, é possível construir um retrato mais preciso da qualidade dos planos de voos propostos. Com essa

unificação foi possível verificar que mesmo evitando colisões o plano de voo proposto sofreu de 30 a 80% de falhas em todos os drones, sendo a maioria por insuficiência energética.

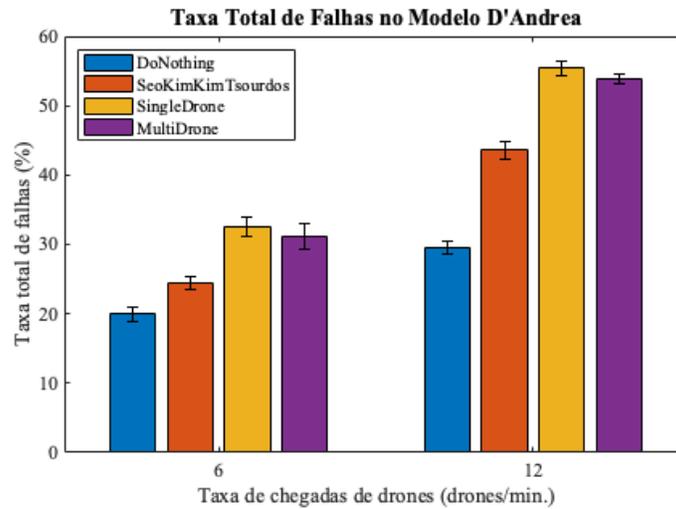


Figura 6: Taxa total de falhas no modelo D'Andrea

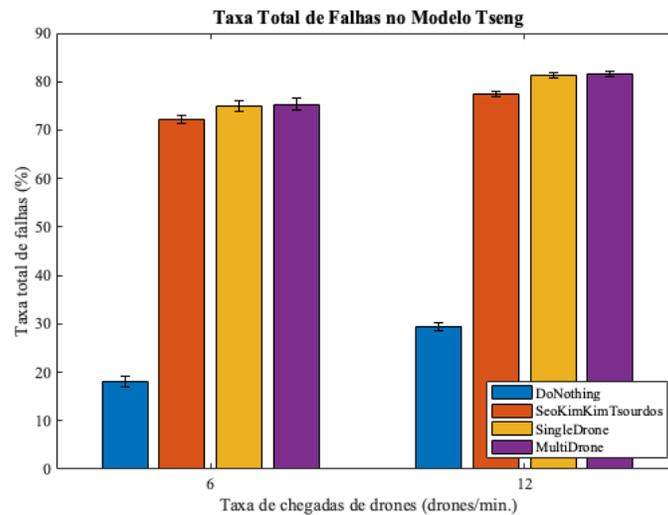


Figura 7: Taxa total de falhas no modelo Tseng

7 Conclusão

Realizar uma análise detalhada do desempenho energético e a eficácia de planos de voos de frotas de drones autônomos de entrega urbana requer compreensão do funcionamento e

dos diferentes tipos de baterias existentes, como realizar uma previsão precisa do consumo energético e garantir a detecção, previsão e evasão de colisões. Este trabalho apresentou a construção e o funcionamento dos principais tipos de baterias utilizados no mercado, suas características operacionais e como essas variáveis impactam diretamente no consumo energético do voo. A modelagem dessas baterias e dos modelos de consumo integrados ao FluteSim permitiu fazer uma avaliação mais holística do desempenho das técnicas de evasão de colisão.

Partindo desses conhecimentos os modelos D'Andrea[5] e Tseng[6] foram utilizados para a análise energética. Com o fim de se ter uma linha de base para as análises, foram utilizados os mesmos parâmetros de drone, bateria e carga descritos nos estudos de Tseng[6]. Os experimentos realizados em cenários simulados, com diferentes densidades de drones e condições críticas de bateria, revelaram importantes insights sobre o impacto do consumo energético e as taxas de colisão em operações de alta densidade.

Os resultados mostraram que o modelo Tseng, por ser um modelo empírico, produzia um consumo de energia mais preciso e mais elevado, gerando taxas de falha na bateria muito maiores em comparação com o modelo integrado generalista D'Andrea. Também foi possível observar uma dualidade inversa entre taxa de colisão e falha na bateria, evidenciando que técnicas com maiores taxas de prevenção de colisão geram maior consumo de energia como consequência dos desvios feitos pelos drones. A densidade de drones também é um fator agravante tanto no risco de colisões quanto na insuficiência energética. Os planos de voos com drones configurados com apenas 20% da bateria simulam condições reais de operação em um último ciclo de entrega, quando os drones já estão com suas baterias em condições críticas. Os resultados indicaram que, nessas condições, as taxas de falha total tornam inviável a execução segura das missões sem um sistema de gerenciamento de carga eficiente ou um recarregamento das baterias antes do voo.

Este trabalho conclui que para o sucesso de um frota de drones autônomos não basta apenas evitar colisões, mas também garantir eficiência energética. Como principais pontos de estudos e pesquisas futuras estão o desenvolvimento de modelos de consumo energético mais precisos e consistentes. Com isso, será possível realizar análises mais completas e mais realistas das técnicas de evasão de colisão. Por fim, aumentar os cenários de teste para cobrir áreas maiores e voos de maior duração permitirá uma análise mais abrangente das limitações e potencialidades dessas tecnologias em ambientes urbanos complexos.

Referências

- [1] SOARES, Lucas de Paula; OLIVEIRA, Fabíola M. C. de; KAMIENSKI, Carlos A.; BITTENCOURT, Luiz F. *Computação na borda para drones: gerenciando pousos e decolagens em centros de distribuição*. Campinas: Universidade Estadual de Campinas, 2023.
- [2] OLIVEIRA, Fabíola M. C. de; BITTENCOURT, Luiz F.; BIANCHI, Reinaldo A. C.; KAMIENSKI, Carlos A. *Drones in the big city: autonomous collision avoidance for aerial delivery services*. IEEE Transactions on Intelligent Transportation Systems, v. 25, n. 5, p. 4657-4673, 2024.

- [3] A. Al-Mousa, B. H. Sababha, N. Al-Madi, A. Barghouthi, and R. Younis, *UTSim: A framework and simulator for UAV air traffic integration, control, and communication*, International Journal of Advanced Robotic Systems, vol. 16, no. 5, 2019. <https://doi.org/10.1177/1729881419870937>.
- [4] Juan Zhang, James F. Campbell, Donald C. Sweeney II, Andrea C. Hupman, *Energy consumption models for delivery drones: A comparison and assessment*, Transportation Research Part D: Transport and Environment, Volume 90, 2021, 102668, ISSN 1361-9209. <https://doi.org/10.1016/j.trd.2020.102668>.
- [5] R. D'Andrea, *Guest Editorial Can Drones Deliver?*, in IEEE Transactions on Automation Science and Engineering, vol. 11, no. 3, pp. 647-648, July 2014, doi: 10.1109/TASE.2014.2326952.
- [6] R. Alyassi, M. Khonji, A. Karapetyan, S. C. -K. Chau, K. Elbassioni and C. -M. Tseng, *Autonomous Recharging and Flight Mission Planning for Battery-Operated Autonomous Drones*, in IEEE Transactions on Automation Science and Engineering, vol. 20, no. 2, pp. 1034-1046, April 2023, doi: 10.1109/TASE.2022.3175565.
- [7] Kardasz, Piotr & Doskocz, Jacek. (2016). *Drones and Possibilities of Their Using*. *Journal of Civil & Environmental Engineering*. 6. 10.4172/2165-784X.1000233.
- [8] Bradley, Thomas & Moffitt, Blake & Fuller, Thomas & Mavris, Dimitri & Parekh, David. (2008). *Design Studies for Hydrogen Fuel Cell Powered Unmanned Aerial Vehicles*. 10.2514/6.2008-6413.
- [9] J. Seo, Y. Kim, S. Kim, and A. Tsourdos, *Collision avoidance strategies for unmanned aerial vehicles in formation flight*, IEEE Trans. Aerosp. Electron. Syst., vol. 53, no. 6, pp. 2718–2734, Dec. 2017.