



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO

LUAN CARLOS SOARES LINS

**MODELAGEM ESTOCÁSTICA DE SISTEMAS DE VIGILÂNCIA COM DRONES
PARA AVALIAÇÃO, PLANEJAMENTO E MELHORIA DO DESEMPENHO E DA
DISPONIBILIDADE**

Recife

2024

LUAN CARLOS SOARES LINS

**MODELAGEM ESTOCÁSTICA DE SISTEMAS DE VIGILÂNCIA COM DRONES
PARA AVALIAÇÃO, PLANEJAMENTO E MELHORIA DO DESEMPENHO E DA
DISPONIBILIDADE**

Dissertação apresentada ao Programa de Pós- Graduação em Ciências da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciências da Computação.

Área de Concentração: Redes de Computadores e Sistemas Distribuídos.

Orientador (a): Dr. Paulo Romero Martins Maciel

Coorientador (a): Dr. Jean Carlos Teixeira de Araujo

Recife

2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Lins, Luan Carlos Soares.

Modelagem estocástica de sistemas de vigilância com drones para avaliação, planejamento e melhoria do desempenho e da disponibilidade / Luan Carlos Soares Lins. - Recife, 2024.

111 f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro de Informática, Programa de Pós-Graduação em Ciência da Computação, 2024.

Orientação: Paulo Romero Martins Maciel.

Coorientação: Jean Carlos Teixeira de Araujo.

Inclui referências e apêndices.

1. Veículos Aéreos Não Tripulados (VANTs); 2. Sistemas de vigilância; 3. Modelagem estocástica; 4. Confiabilidade; 5. Disponibilidade; 6. Performabilidade. I. Maciel, Paulo Romero Martins. II. Araujo, Jean Carlos Teixeira de. III. Título.

UFPE-Biblioteca Central

Luan Carlos Soares Lins

“MODELAGEM ESTOCÁSTICA DE SISTEMAS DE VIGILÂNCIA COM DRONES PARA AVALIAÇÃO, PLANEJAMENTO E MELHORIA DO DESEMPENHO E DA DISPONIBILIDADE”

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação. Área de Concentração: Redes de Computadores e Sistemas Distribuídos.

Aprovado em: 30/10/2024.

BANCA EXAMINADORA

Prof. Dr. Jamilson Ramalho Dantas
Centro de Informática / UFPE

Prof. Dr. Rubens de Souza Matos Júnior
Coordenadoria de Informática / IFSE

Prof. Dr. Paulo Romero Martins Maciel
Centro de Informática / UFPE
(orientador)

Dedico ao meu avô, Edvaldo Barbosa Ramos (in memoriam), cujos exemplos de honestidade e persistência continuam a me inspirar em todas as conquistas. Seu legado vive em cada página deste trabalho.

AGRADECIMENTOS

Ao concluir esta etapa significativa de minha jornada acadêmica, sinto-me profundamente grato por todos aqueles que contribuíram para tornar este momento possível.

Primeiramente, elevo minha gratidão a Deus, fonte inesgotável de força e inspiração que me guiou ao longo deste caminho desafiador.

Aos meus pais, Paulo e Lindinalva, dedico meu mais profundo reconhecimento. Vocês não apenas me deram a vida, mas a preencheram com amor, sacrifício e uma inabalável crença em meu potencial. Mãe, sua resiliência e amor incondicional foram meu porto seguro nos momentos mais turbulentos. Pai, seu exemplo de integridade e dedicação moldou o homem que me tornei. Ao meu irmão, Paulo Júnior, agradeço pelo companheirismo constante e pelo apoio que transcende as palavras.

Estendo minha gratidão a toda minha família - avós, tios, tias e primos. Cada um de vocês, à sua maneira, contribuiu para minha formação e para a realização deste sonho. Seus sacrifícios e incentivos não passaram despercebidos e são parte integrante desta conquista.

No âmbito acadêmico, expresso minha mais sincera gratidão ao Professor Paulo Maciel, meu orientador de mestrado. Sua orientação transcendeu os limites da academia, moldando não apenas minha pesquisa, mas minha visão do mundo científico. Ao Professor Jean Carlos, meu coorientador, sou grato pela dedicação incansável, pelos conselhos precisos e pelo apoio que foi além das expectativas.

Aos membros do grupo de pesquisa Modeling of Distributed and Concurrent Systems (MoDCS), meu reconhecimento pelo ambiente colaborativo e estimulante que proporcionaram. As discussões, trocas de ideias e o suporte mútuo foram fundamentais para o desenvolvimento deste trabalho e para meu crescimento como pesquisador.

Um agradecimento especial é dedicado aos meus amigos da Localhost - Felipe, Erick e Paulinho. Nossa amizade, forjada nos desafios e celebrações compartilhadas, provou-se um tesouro inestimável. Vocês trouxeram leveza aos momentos difíceis e multiplicaram a alegria nas conquistas.

A todos os amigos que fiz durante esta jornada, especialmente no MoDCS, meu sincero obrigado. Vocês enriqueceram esta experiência com suas perspectivas únicas, apoio constante e momentos de descontração que tornaram o caminho mais prazeroso.

Por fim, reconheço minha própria perseverança e dedicação. Esta jornada de mestrado me

ensinou lições valiosas sobre resiliência, autoconhecimento e a importância de perseguir os sonhos com determinação.

A cada pessoa que, direta ou indiretamente, contribuiu para a realização deste trabalho e para meu desenvolvimento acadêmico e pessoal, expresso minha mais profunda gratidão. Este mestrado não é apenas uma conquista individual, mas o resultado de uma rede de apoio, conhecimento e afeto que me cercou.

"O que foi, isso é o que há de ser; e o que se fez, isso se fará; de modo que nada há de novo debaixo do sol." (Eclesiastes 1:9).

RESUMO

Este trabalho tem como objetivo principal desenvolver modelos para otimização de sistemas de vigilância com Veículos Aéreos Não Tripulados (VANTs), também chamados de drones, integrando análises de confiabilidade, disponibilidade e performabilidade. Ao contrário de estudos anteriores que tratam esses aspectos de maneira isolada, esta pesquisa apresenta uma metodologia integrada que utiliza modelos analíticos, como Cadeias de Markov de Tempo Contínuo, e modelos numéricos, como Redes de Petri Estocásticas, a um modelo de cobertura que considera tanto as características das câmeras quanto os parâmetros operacionais dos drones. Esta abordagem integrada permite uma avaliação mais precisa e abrangente do desempenho do sistema. Os resultados das análises de sensibilidade e estudos de caso revelaram que a redundância de baterias tem um impacto significativo na disponibilidade do sistema. Aumentar o número de baterias sobressalentes de 1 para 6 elevou o *throughput* do sistema em 70%, de 10 para 17 rondas por hora. Para missões de longa duração (30 horas), manter entre 15 e 20 baterias redundantes pode garantir uma confiabilidade acima de 80%. Otimizações no gerenciamento de energia, como reduzir o tempo de carregamento da bateria para menos de 36 minutos e utilizar baterias com tempos de descarga superiores a 144 minutos, podem reduzir o tempo de inatividade anual de aproximadamente 100 horas para menos de 20 horas. A metodologia desenvolvida permite aos projetistas equilibrar quantitativamente métricas de desempenho, disponibilidade e custo, oferecendo diretrizes práticas para o dimensionamento eficiente de sistemas de vigilância com drones. Esta pesquisa se destaca por fornecer uma abordagem abrangente que integra múltiplos aspectos do desempenho do sistema, permitindo uma otimização mais eficaz e baseada em dados quantitativos.

Palavras-chave: Veículos Aéreos Não Tripulados (VANTs), Drones, Sistemas de Vigilância, Modelagem Estocástica, Redes de Petri Estocásticas, Cadeias de Markov, Confiabilidade, Disponibilidade, Performabilidade, Análise de Sensibilidade, Redundância, Gerenciamento de Energia, Otimização de Sistemas.

ABSTRACT

This work's main objective is to develop models for optimizing surveillance systems with Unmanned Aerial Vehicles (UAVs), also known as drones, integrating analyses of reliability, availability, and performability. Unlike previous studies that treat these aspects in isolation, this research presents an integrated methodology that uses analytical models, such as Continuous Time Markov Chains, and numerical models, such as Stochastic Petri Nets, with a coverage model that considers both camera characteristics and operational parameters of drones. This integrated approach allows for a more precise and comprehensive evaluation of system performance. The results of sensitivity analyses and case studies revealed that battery redundancy has a significant impact on system availability. Increasing the number of spare batteries from 1 to 6 raised the system throughput by 70%, from 10 to 17 rounds per hour. For long-duration missions (30 hours), maintaining between 15 and 20 redundant batteries can ensure reliability above 80%. Optimizations in energy management, such as reducing battery charging time to less than 36 minutes and using batteries with discharge times exceeding 144 minutes, can reduce annual downtime from approximately 100 hours to less than 20 hours. The developed methodology allows designers to quantitatively balance performance, availability, and cost metrics, offering practical guidelines for efficient sizing of drone surveillance systems. This research stands out by providing a comprehensive approach that integrates multiple aspects of system performance, enabling more effective optimization based on quantitative data.

Keywords: Unmanned Aerial Vehicles (UAVs), Drones, Surveillance Systems, Stochastic Modeling, Stochastic Petri Nets, Markov Chains, Reliability, Availability, Performability, Sensitivity Analysis, Redundancy, Energy Management, Systems Optimization.

LISTA DE FIGURAS

Figura 1 – Tecnologias de Carregamento	20
Figura 2 – Classificação de Drones	29
Figura 3 – Arquitetura e Componentes	31
Figura 4 – Aplicações de Drones	32
Figura 5 – Árvore de Dependabilidade	35
Figura 6 – Principais Componentes de uma Rede de Petri	40
Figura 7 – Exemplo de uma Rede de Petri	41
Figura 8 – Componentes Adicionais para uma Rede de Petri Estocástica	42
Figura 9 – Visão Geral da Metodologia Adotada para Avaliação de Sistemas de Vigilância por Drones.	47
Figura 10 – Modelos de Avaliação Propostos para Sistemas de Monitoramento por VANTs e suas Inter-relações.	52
Figura 11 – Arquitetura de Vigilância por Drones Ilustrando o Campo de Visão e a Altura Operacional.	53
Figura 12 – Gráfico de Alcançabilidade para Disponibilidade de Sistemas de Vigilância por Drone	55
Figura 13 – Modelo de Disponibilidade CTMC para Sistemas de Vigilância por Drone .	56
Figura 14 – Modelo de Disponibilidade Usando SPN para Sistemas de Vigilância por Drone	62
Figura 15 – Modelo de Confiabilidade Usando SPN para Sistemas de Vigilância por Drone	64
Figura 16 – Área de Vigilância Alvo Demonstrando Cobertura de Drones.	69
Figura 17 – Métricas Sobrepostas na Imagem Capturada pelo Drone durante o Monitoramento.	70
Figura 18 – Modelo de Performabilidade Usando SPN para Sistemas de Vigilância por Drones	72
Figura 19 – Relação entre Confiabilidade do Sistema, Tempo de Operação e Número de Baterias Redundantes (BN) durante um Período de 30 Horas	79
Figura 20 – Impacto do Tempo Médio de Carga da Bateria (MTTBC) na Confiabilidade do Sistema Durante 2 Horas de Operação	79

Figura 21 – Efeito do Tempo Médio de Descarga da Bateria (MTTBD) na Confiabilidade do Sistema ao Longo de 2 Horas de Operação.	80
Figura 22 – Impacto do Tempo Médio de Carregamento da Bateria (MTTBC) e do Número de Baterias Sobressalentes (BN) na Disponibilidade do Sistema de Drones.	86
Figura 23 – Impacto do Tempo Médio de Descarga da Bateria (MTTBD) e do Número de Baterias Sobressalentes (BN) na Disponibilidade do Sistema de Drones.	86
Figura 24 – Impacto do Número de Drones (DN) e Baterias Sobressalentes (BN) na Disponibilidade do Sistema de Drones.	88
Figura 25 – Rondas de Vigilância Realizadas por Hora pelo Drone.	89
Figura 26 – Probabilidade do Drone Esperar pelas Baterias.	89
Figura 27 – Número Médio de Baterias Disponíveis.	90
Figura 28 – Análise do Tempo de Inatividade Anual do Sistema (DTyd) em Relação ao Número de Baterias Sobressalentes.	91

LISTA DE CÓDIGOS

Código Fonte 1 – Código-fonte Extração da Fórmula Fechada CTMC	99
Código Fonte 2 – Código-fonte Validação do Modelo de Cobertura	100
Código Fonte 3 – Script Mercury Modelo de Disponibilidade	102
Código Fonte 4 – Script Mercury Modelo de Confiabilidade	103
Código Fonte 5 – Script Mercury Modelo de Performabilidade	106

LISTA DE QUADROS

Quadro 1 – Comparação de Trabalhos Relacionados	25
Quadro 2 – Descrição dos Estados do Sistema para o Modelo CTMC	58
Quadro 3 – Descrição dos Parâmetros para o Modelo CTMC	58
Quadro 4 – Parâmetros Associados a Transições dos Modelos de Disponibilidade e Confiabilidade SPN	63
Quadro 5 – Parâmetros Modelo de Tempo de Cobertura	66

LISTA DE TABELAS

Tabela 1 – Especificações do Teste de Validação	70
Tabela 2 – Parâmetros de Avaliação do Modelo de Confiabilidade.	78
Tabela 3 – Parâmetros de Dimensionamento do Sistema de Vigilância por Drone	83
Tabela 4 – Classificação de Sensibilidade	84
Tabela 5 – Parâmetros de Avaliação de Performabilidade	85

LISTA DE ABREVIATURAS E SIGLAS

AVGBA	Average Number of Batteries Available
BDD	Binary Decision Diagrams
CMOS	Complementary Metal-Oxide-Semiconductor
CTMC	Continuous-time Markov Chains
DSPN	Deterministic Stochastic Petri Nets
DTMC	Discrete Time Markov Chain
eDSPN	Deterministic and Stochastic Petri Nets
FAA	Federal Aviation Administration
FOV	Field of View
GCS	Ground Control Station
GSPN	Generalized Stochastic Petri Nets
HAP	High Altitude Platform
ISS	Infinite Server Semantics
LAP	Low Altitude Platform
LIDAR	Light Detection and Ranging
LiPo	Lithium Polymer
LPT	Laser Power Transmission
MNI	Mean Number of Items
MoDCS	Modeling of Distributed and Concurrent Systems
MTTBC	Mean Time to Battery Charging
MTTBD	Mean Time to Battery Discharge
MTTDF	Mean Time to Drone Failure
MTTDR	Mean Time to Drone Repair
MTTDS	Mean Time to Drone Swap
MTTF	Mean Time to Failure

MTTR	Mean Time to Repair
PDWB	Probability of Drone Waiting for Batteries
PH	Phase-type
PN	Petri Nets
RBD	Reliability Block Diagram
SF	System Failure
SI	Sensitivity Index
SLA	Service Level Agreement
SPN	Stochastic Petri Nets
SSS	Single Server Semantics
SysML	Systems Modeling Language
TTSF	Time to System Failure
VANT	Veículo Aéreo Não Tripulado
WPT	Wireless Power Transfer

LISTA DE SÍMBOLOS

γ Letra grega Gama

ϵ Pertence

δ Delta

θ Teta

σ Sigma

μ Mi

ϕ Fi

ψ Psi

CoV_{time} Coverage Time

SUMÁRIO

1	INTRODUÇÃO	19
1.1	MOTIVAÇÃO E JUSTIFICATIVA	22
1.2	OBJETIVOS	22
1.3	TRABALHOS RELACIONADOS	22
1.4	ESTRUTURA DA DISSERTAÇÃO	27
2	FUNDAMENTAÇÃO	28
2.1	VEÍCULO AÉREO NÃO TRIPULADO - VANT	28
2.1.1	Arquitetura e Componentes	30
2.1.2	Aplicabilidades e Benefícios	32
2.2	DEPENDABILIDADE	34
2.3	MODELOS ESTOCÁSTICOS	38
2.3.1	Cadeias de Markov de Tempo Contínuo - CTMC	38
2.3.2	Redes de Petri Estocásticas - SPN	40
2.4	ANÁLISE DE SENSIBILIDADE	45
3	METODOLOGIA	47
4	ARQUITETURA E MODELOS	52
4.1	MODELO DE DISPONIBILIDADE	54
4.1.1	Modelo de Redundância SPN	60
4.2	MODELO DE CONFIABILIDADE	63
4.3	MODELO DE COBERTURA	65
4.3.1	Validação do Modelo de Cobertura	69
4.4	MODELO DE PERFORMABILIDADE	71
5	ESTUDOS DE CASO	76
5.1	ESTUDO DE CASO #1	77
5.2	ESTUDO DE CASO #2	82
6	CONCLUSÕES	92
	REFERÊNCIAS	94
	APÊNDICE A – CÓDIGOS-FONTE DE DESENVOLVIMENTO . . .	99
	APÊNDICE B – SCRIPTS DE DESENVOLVIMENTO	102

1 INTRODUÇÃO

No cenário contemporâneo, a gestão eficaz e segura de multidões é um desafio premente no nosso mundo cada vez mais interligado e urbanizado. Organizações e indústrias estão adotando rapidamente a tecnologia de Veículo Aéreo Não Tripulado (VANT) para automatizar tarefas complexas. Os VANTS podem voar em grandes altitudes para expandir seu alcance de visão e explorar espaços livres de obstáculos (MASMOUDI et al., 2021). Especificamente, as agências de aplicação da lei estão recorrendo aos VANTS para investigar crimes e gerir multidões, especialmente durante eventos públicos significativos (MASMOUDI et al., 2021). Além disso, o uso de câmeras fixas para monitorar grandes áreas abertas tem se mostrado ineficiente devido à pequena cobertura de uma única câmera (YANG et al., 2021; PUNN et al., 2020). Isto levou à crescente adoção de VANTS para atender a esta necessidade de monitoramento abrangente.

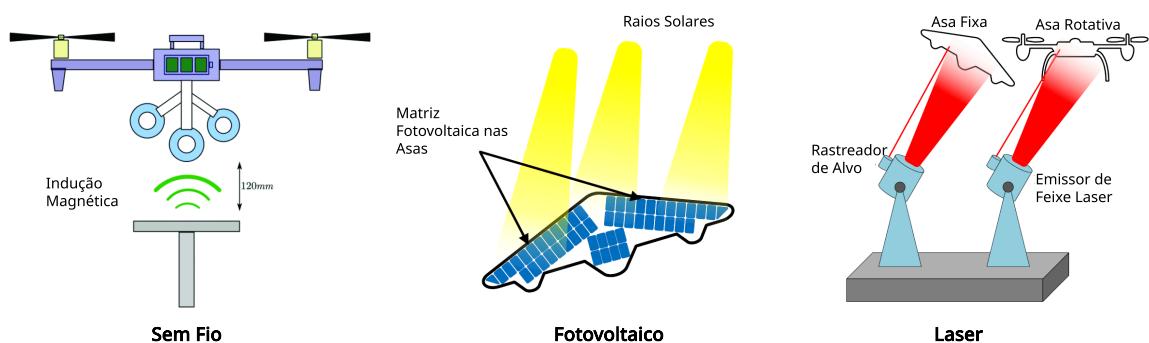
Apesar das vantagens dos VANTS, como a sua capacidade de voar em diferentes altitudes e os baixos custos de operação e manutenção (SHAKHATREH et al., 2019), eles enfrentam vários desafios, incluindo a capacidade limitada de suas baterias, que restringe o tempo e as capacidades de voo (MOHSAN et al., 2022). Além disso, os desafios relacionados ao reconhecimento de objetos podem impactar significativamente a qualidade do serviço, especialmente em situações que envolvem altitudes de cobertura elevadas e sensores de câmeras de baixa resolução. Algoritmos de processamento de imagem mais avançados, como redes neurais e técnicas de aprendizado de máquina, como *deep learning*, podem exigir energia substancial, afetando ainda mais a autonomia do drone. Isso requer um planejamento cuidadoso para maximizar a eficiência.

Em resposta a estes desafios, várias soluções foram propostas para aumentar o tempo de voo dos VANTS, incluindo expansão da capacidade da bateria, carregamento intermitente e otimização das trajetórias de voo (MOHSAN et al., 2022; ZHANG et al., 2021). No entanto, expandir a capacidade da bateria é um desafio devido ao peso adicional que isso acarreta (MOHSAN et al., 2022; LU et al., 2018). Além disso, os VANTS enfrentam restrições regulatórias, como as impostas pela Administração Federal de Aviação, Federal Aviation Administration (FAA), que incluem limites de altitude, velocidade e requisitos de linha de visão (SHAKHATREH et al., 2019). Estas regulamentações podem limitar a eficiência dos VANTS em aplicações como sistemas de entrega, e as exigências regulatórias variam conforme a jurisdição, dificultando a implementação de soluções em múltiplos países.

A incorporação de sistemas de rastreamento baseados em VANT também enfrenta obstáculos técnicos, como camuflagem e condições climáticas adversas (LEE; SONG; KIL, 2021). Ambientes extremos, como tempestades, podem comprometer a estabilidade e funcionamento dos VANTs, exigindo adaptações complexas e custosas (SHAKHATREH et al., 2019). Apesar desses desafios, os VANTs oferecem uma solução eficiente, de baixo custo e alta confiabilidade para diversas aplicações, incluindo monitoramento agrícola (ZHANG et al., 2021; SAAD; HAMDAN; SARKER, 2021), missões de resgate (SANDINO et al., 2020), tarefas militares (ABUSHAHMA et al., 2019), transporte e rastreamento de pessoas (SHAKHATREH et al., 2019; OJHA; SAKHARE, 2015). Em particular, para o rastreamento de objetos, os VANTs podem fornecer com rapidez e precisão a localização de objetos e imagens do seu entorno, economizando tempo e recursos em diferentes cenários (ALHAFNAWI et al., 2023).

Apesar desses desafios, a tecnologia VANT continua sendo promissora para vigilância autônoma e missões de rastreamento de animais, especialmente em áreas grandes e inacessíveis (SHAKHATREH et al., 2019). Recentes avanços em tecnologias de carregamento de VANTs focam na eficiência e prática de sistemas de transferência de energia sem fio, Wireless Power Transfer (WPT), essenciais para aumentar as capacidades operacionais e a sustentabilidade dos VANTs. A Figura 1 ilustra três principais tecnologias de carregamento para VANTs: sem fio, fotovoltaico e a laser, destacando abordagens inovadoras.

Figura 1 – Tecnologias de Carregamento



Fonte: Baseado em CHITTOOR; CHOKKALINGAM; MIHET-POPA (2021)

Os métodos de carregamento sem fio evoluíram consideravelmente, principalmente por meio de acoplamento de ressonância magnética e estruturas de bobinas otimizadas, que facilitam uma transferência de energia mais eficiente e reduzem o tempo de inatividade dos VANTs. A integração de estações de carregamento autônomas também tem sido um avanço significativo (CHITTOOR; CHOKKALINGAM; MIHET-POPA, 2021). Além disso, as tecnologias de

carregamento sem fio permitem que os VANTs operem em missões de longa duração sem a necessidade de pousar, utilizando plataformas de recarga em voo para estender significativamente o tempo de missão.

Técnicas não eletromagnéticas, como transferência de energia a laser, Laser Power Transmission (LPT), permitem carregamento a longas distâncias, essencial para missões em locais remotos. A integração de células fotovoltaicas também é uma abordagem para prolongar a autonomia dos VANTs (MOHSAN et al., 2022). Tais células permitem que os drones aproveitem a luz solar durante o voo, aumentando sua autonomia de maneira sustentável e reduzindo a dependência de infraestruturas terrestres para recarga.

Tecnologias emergentes incluem o uso de blockchain para otimizar e gerenciar os processos de carregamento de VANTs, aumentando a segurança e confiabilidade na infraestrutura de carregamento (MOHSAN et al., 2022). Esses avanços têm um papel crucial na criação de operações mais eficientes, confiáveis e autônomas para VANTs, contribuindo para sua aplicação em setores como agricultura, monitoramento ambiental e cidades inteligentes. Além disso, a integração dessas tecnologias com redes IoT e sistemas de inteligência artificial tem proporcionado maior autonomia e capacidade de decisão aos VANTs, permitindo que esses dispositivos tomem decisões em tempo real baseadas em dados recebidos de múltiplas fontes.

Goncalves, Sobral e Ferreira (2017) desenvolveram um modelo para Avaliação de Segurança de VANTs, possibilitando a identificação de pontos críticos do sistema que necessitam de melhorias para autorização de voo e certificação de aeronavegabilidade. Sharma et al. (2018) focaram em proteger o compartilhamento de informações de contexto entre VANTs e melhorar a precisão e segurança da localização. Esses estudos exemplificam diversas aplicações de técnicas formais de modelagem e análise para enfrentar os desafios relacionados aos VANT e enfatizar a importância da segurança nas operações de VANT.

Neste contexto, este trabalho apresenta mais uma alternativa para otimização de missões envolvendo operação com VANTS, propondo modelos de avaliação de performance, disponibilidade e confiabilidade para otimizar o planejamento eficiente de sistemas de vigilância implementados com VANTS, considerando as limitações de suas baterias. Para atingir este objetivo, analisamos o planejamento da área de observação e a autonomia do drone, incluindo fatores como tempos de carregamento, duração da bateria e relocação para a estação base.

1.1 MOTIVAÇÃO E JUSTIFICATIVA

A adoção de VANTs por organizações e agências de aplicação da lei para tarefas complexas, como investigação de crimes e gerenciamento de multidões em eventos públicos, está se tornando cada vez mais comum. Uma das principais razões para esta tendência é a ineficiência das câmeras fixas em monitorar grandes áreas abertas, tornando os VANTs uma alternativa atraente devido à sua capacidade de cobrir extensas áreas de observação.

No entanto, os VANTs enfrentam desafios significativos, principalmente relacionados à capacidade limitada de suas baterias, que restringe o tempo de voo e as capacidades operacionais. Além disso, desafios no reconhecimento de objetos podem afetar a qualidade do serviço prestado por esses dispositivos. Para abordar esses problemas, o trabalho propõe modelos para avaliar a performabilidade e otimizar o planejamento de sistemas de vigilância implementados por VANTs. Este modelo considera os fatores operacionais críticos, como tempos de carregamento, vida útil da bateria e a necessidade de realocação dos VANTs para suas estações-base.

1.2 OBJETIVOS

Como objetivo principal é propor modelos de avaliação de desempenho baseado em Cadeias de Markov de Tempo Contínuo, Continuous-time Markov Chains (CTMC) e Redes de Petri Estocásticas, Stochastic Petri Nets (SPN), para otimizar performance, disponibilidade e confiabilidade de sistemas de vigilância baseados em VANTs. Estes modelos devem abordar especificamente desafios como capacidade limitada da bateria e planejamento estratégico para otimizar áreas de observação.

Objetivos secundários:

- Permitir análise de tempos de carregamento e descarga da bateria.
- Permitir análise de tempos de falha e reparo do VANT.
- Permitir análise da aplicação de redundância de baterias e VANTs no sistema.

1.3 TRABALHOS RELACIONADOS

Vários estudos têm sido conduzidos nas áreas relacionadas a esta pesquisa, entretanto, nenhum deles abrange todas as características abordadas neste trabalho. Alguns focam na

confiabilidade de sistemas baseados em VANTs e suas otimizações estruturais, outros investigam alocar recursos e otimização de missões envolvendo enxames de VANTs, enquanto alguns exploram o uso de redes de Petri e cadeias de Markov para modelagem e análise de desempenho em cenários críticos.

A busca por trabalhos foi realizada utilizando uma combinação de palavras-chave relacionadas a drones e VANTs, com foco em vigilância e confiabilidade de sistemas. As palavras-chave utilizadas incluíram termos como "drone", "veículo aéreo não tripulado (VANT)", "vigilância", "confiabilidade", "disponibilidade", "dependabilidade", "modelagem", "redes de Petri estocásticas", "cadeias de Markov", "redundância de baterias", "missões de confiabilidade", "análise de sensibilidade", "computação aérea", "avaliação de desempenho", entre outros.

O objetivo foi encontrar estudos que abordassem temas como a confiabilidade de sistemas baseados em VANTs, a disponibilidade em sistemas de vigilância aérea e o uso de métodos analíticos e estocásticos para melhorar o desempenho desses sistemas. A pesquisa abrangeu trabalhos publicados entre 2019 e 2024, consultando bibliotecas digitais importantes como ACM Digital Library, ScienceDirect, SpringerLink e IEEEExplore, e priorizou estudos que exploraram soluções para otimizar missões críticas envolvendo VANTs.

Os estudos mais pertinentes para o desenvolvimento desta dissertação foram escolhidos considerando suas contribuições específicas e a maneira como se conectam com o foco central desta pesquisa. Em FENG et al. (2022), por exemplo, a confiabilidade de missões em fases é avaliada utilizando medidas de importância para determinar o número ideal de VANTs em um enxame, destacando a influência da quantidade de VANTs na confiabilidade da missão. Embora este trabalho contribua para a compreensão da otimização de sistemas distribuídos, sua abordagem é limitada por focar principalmente na quantidade de VANTs, negligenciando outros fatores críticos como eficiência energética e adaptabilidade a falhas em tempo real. Já DUI et al. (2021), complementa esse estudo ao explorar a redundância de VANTs e como ela pode manter a missão em andamento mesmo diante de falhas, alinhando-se ao nosso objetivo de garantir alta disponibilidade. No entanto, este estudo não aborda adequadamente a otimização dinâmica de recursos durante a missão, uma lacuna que nossa pesquisa preenche ao propor estratégias adaptativas de alocação de recursos.

Além disso, trabalhos como o de JIANG; QI et al. (2024) avançam essa discussão ao propor métodos para o planejamento de testes operacionais em enxames de VANTs, focando na aplicação de diagramas de decisão binária para otimizar a confiabilidade de missões críticas. Esse estudo é fundamental para validar a eficácia de enxames de VANTs em cenários com-

plexos. Embora esse estudo seja fundamental para validar a eficácia de enxames de VANTs em cenários complexos, sua abordagem apresenta limitações significativas. O uso exclusivo de diagramas de decisão binária pode não capturar adequadamente a natureza dinâmica e as interações complexas em sistemas de enxames de VANTs. Semelhantemente, ZHAO; WANG (2019) e BRITO et al. (2021) utilizam redes de Petri estocásticas para analisar o desempenho e a disponibilidade de sistemas colaborativos de VANTs, com foco na avaliação de arquiteturas distribuídas. Embora estas abordagens ofereçam insights sobre o comportamento de sistemas distribuídos, esse estudo não aborda adequadamente a otimização em tempo real de recursos e a adaptação dinâmica a falhas, aspectos cruciais para missões de longa duração.

KABASHKIN (2024) destaca a importância de estratégias dinâmicas de alocação de recursos, como a gestão de baterias, para garantir operações contínuas em missões de alta prioridade. Esse trabalho está diretamente relacionado à proposta desta dissertação de otimizar a confiabilidade e a disponibilidade de drones em missões prolongadas. Apesar de sua relevância, o estudo não integra plenamente essas estratégias com modelos de confiabilidade e disponibilidade, uma síntese que nossa pesquisa realiza para uma abordagem mais holística. Complementarmente, FALCÃO et al. (2024) utilizam cadeias de Markov para otimizar o consumo de energia em sistemas VANT, uma abordagem crucial para a melhoria da eficiência energética e da disponibilidade operacional.

Por outro lado, XING; JOHNSON (2022) exploram a teoria da confiabilidade aplicada a sistemas VANT, destacando o uso de modelos como diagramas de blocos de confiabilidade, Reliability Block Diagram (RBD) e diagramas de decisão binária, Binary Decision Diagrams (BDD), abordagens que complementam as metodologias utilizadas neste trabalho para modelar a confiabilidade de sistemas utilizando VANT. Embora esses modelos sejam importantes, eles não incorporam adequadamente a natureza dinâmica e adaptativa das missões de longa duração com VANTs, uma lacuna que nossa metodologia visa preencher por meio de modelos mais flexíveis. Já LI et al. (2024), ao proporem uma metodologia de otimização de interferências aleatórias para testar a confiabilidade de VANTs, reforçam o uso de técnicas de otimização para melhorar a robustez dos sistemas em missões críticas.

Finalmente, o trabalho de STEURER et al. (2019), que utiliza Linguagem de Modelagem de Sistemas, Systems Modeling Language (SysML) e cadeias de Markov para modelar sistemas de navegação inercial em VANTs, oferece uma abordagem para a análise de confiabilidade em sistemas embarcados, alinhada à proposta deste trabalho de utilizar metodologias analíticas para otimizar a confiabilidade de missões prolongadas. Embora esta abordagem seja bastante

prática, para ambiente mais complexo onde é considerada redundância de componentes, este modelo fica limitado. A análise de dependabilidade e a aplicação prática de metodologias de sistemas baseados em modelos também encontram correlação com os estudos de BRITO et al. (2021), que analisam a confiabilidade em sistemas de comunicação distribuídos com VANTS, utilizando redes de Petri estocásticas para avaliação de desempenho. Apesar de sua contribuição para a avaliação de desempenho, o estudo não integra plenamente aspectos de otimização de energia e redundância, áreas que nossa pesquisa aborda de forma mais ampla.

Quadro 1 – Comparação de Trabalhos Relacionados

Trabalhos	Contexto	Modelagem Estocástica	Modelo Analítico (Fórmula)	Modelo de Cobertura	Confiabilidade	Disponibilidade	Performance	Performabilidade	Análise de Sensibilidade
DUI et al. (2021)	Enxame de VANTS	✓	✓						
FENG et al. (2022)	Enxame de VANTS	✓	✓						
KABASHKIN (2024)	Enxame de VANTS	✓	✓						
JIANG; QI et al. (2024)	Enxame de VANTS	✓	✓						
ZHAO; WANG (2019) P	Enxame de VANTS	✓	✓				✓		
SABINO et al. (2024) P	Vigilância	✓					✓		
FALCÃO et al. (2024)	Comunicação	✓	✓				✓		
BRITO et al. (2021)	Comunicação	✓		✓	✓			✓	
STEURER et al. (2020)	Vigilância	✓		✓					
KUMARI et al. (2024)	Vigilância	✓		✓					
STEURER et al. (2019)	Vigilância			✓					
LI et al. (2024)	Enxame de VANTS	✓		✓					
LIAN et al. (2021)	Comunicação	✓		✓					
Este Trabalho	Vigilância	✓	✓	✓	✓	✓	✓	✓	✓

Fonte: Elaborado pelo Autor (2024)

O Quadro 1 apresenta uma comparação detalhada dos trabalhos relacionados, revelando tendências e lacunas importantes na literatura atual. Observa-se que, enquanto a maioria dos estudos foca em aspectos específicos como modelagem estocástica ou análise de confiabilidade, poucos abordam de forma integrada todos os aspectos críticos para sistemas de vigilância baseados em VANTs.

Analizando o Quadro 1, nota-se que BRITO et al. (2021) apresenta uma abordagem mais abrangente, incluindo análises de confiabilidade, disponibilidade e performance. No entanto, este estudo se concentra em computação em nuvem, não abordando as especificidades dos sistemas de vigilância com VANTs. Nossa pesquisa se diferencia ao integrar todos esses aspectos no contexto específico de vigilância aérea, incluindo adicionalmente um modelo de cobertura e análise de performabilidade.

As abordagens metodológicas utilizadas nos estudos revisados variam significativamente. Enquanto FENG et al. (2022) e DUI et al. (2021) empregam principalmente modelagem estocástica para análise de confiabilidade, nossa pesquisa propõe uma metodologia mais abrangente. Integramos modelagem estocástica com análise de performabilidade e otimização de recursos, permitindo uma avaliação mais completa e realista dos sistemas de vigilância baseados em VANTs.

Esta revisão da literatura revela uma tendência crescente em direção à análise multifacetada de sistemas complexos, como os de vigilância com VANTs. No entanto, identifica-se uma oportunidade significativa para desenvolver um framework integrado que considere simultaneamente aspectos de confiabilidade, disponibilidade, performance e planejamento de cobertura.

Nossa pesquisa se propõe a preencher essas lacunas, oferecendo uma abordagem inovadora que integra modelagem estocástica, análise de confiabilidade e disponibilidade, otimização de recursos e planejamento de cobertura. Consideramos as especificidades dos sistemas de vigilância baseados em VANTs, incluindo a dinâmica de operações em ambientes complexos. Propomos um modelo de performabilidade que captura as interações entre performance e disponibilidade, uma abordagem não explorada adequadamente nos estudos anteriores. Além disso, incluímos uma análise de sensibilidade para avaliar o impacto de diferentes parâmetros na eficácia global do sistema.

Ao abordar estas limitações e integrar múltiplos aspectos críticos, este estudo visa contribuir significativamente para o avanço do conhecimento na área de sistemas de vigilância baseados em VANTs, proporcionando *insights* para o desenvolvimento de sistemas mais eficientes e

confiáveis. A abordagem holística proposta não apenas preenche as lacunas identificadas na literatura existente, mas também estabelece uma base sólida para futuras pesquisas e aplicações práticas no campo da vigilância aérea automatizada.

1.4 ESTRUTURA DA DISSERTAÇÃO

Este trabalho segue estruturado da seguinte forma: O Capítulo 2 detalha os conceitos de avaliação e performabilidade, campo de visão, distribuição poliexponencial, redes de Petri e análise de sensibilidade utilizados neste estudo; O Capítulo 3 descreve a metodologia utilizada para realizar este estudo. Fórmulas de dimensionamento do sistema e um modelo numérico de performance em redes de Petri são apresentados em detalhes no Capítulo 4. Além disso, O Capítulo 5 apresenta dois estudos de caso que analisam o impacto da redundância e melhorias de tempo em drones e baterias na disponibilidade, tempo de inatividade e desempenho no número de rondas de vigilância realizadas por unidade de tempo do sistema e os resultados encontrados. Finalmente, nosso trabalho termina no Capítulo 6, onde tiramos conclusões dos resultados e discutimos possíveis direções para trabalhos futuros.

2 FUNDAMENTAÇÃO

Este capítulo apresenta os fundamentos teóricos essenciais para a compreensão do trabalho desenvolvido. Inicialmente, abordamos os VANTs, explorando sua classificação, arquitetura e aplicações. Em seguida, discutimos o conceito de dependabilidade em sistemas computacionais, incluindo seus atributos, ameaças e meios de alcançá-la. Por fim, apresentamos uma visão geral sobre modelos estocásticos, com ênfase nas Cadeias de Markov de Tempo Contínuo (CTMC) e nas Redes de Petri Estocásticas (SPN), ferramentas fundamentais para a análise de desempenho e confiabilidade de sistemas complexos.

A compreensão desses conceitos é importante para o desenvolvimento de sistemas robustos e confiáveis, especialmente no contexto de VANTs, onde a segurança e o desempenho são fatores relevantes. Os VANTs representam uma tecnologia em evolução, com aplicações que incluem agricultura de precisão e operações de vigilância, demandando confiabilidade e eficiência. A dependabilidade fornece um framework para avaliar e melhorar a confiabilidade e disponibilidade desses sistemas. Os modelos estocásticos, como as CTMCs e SPNs, oferecem ferramentas para modelar e analisar o comportamento desses sistemas sob condições de incerteza, permitindo prever e otimizar seu desempenho em diversos cenários operacionais.

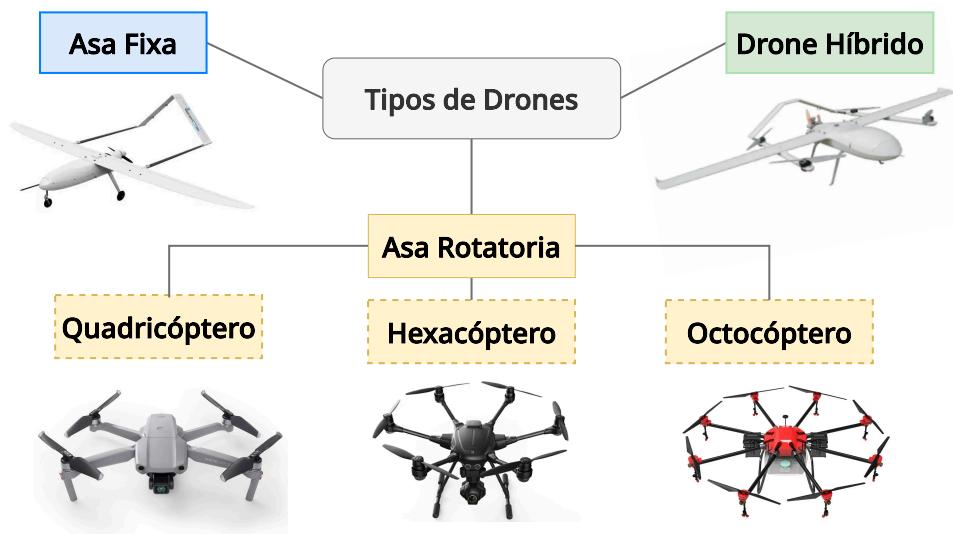
2.1 VEÍCULO AÉREO NÃO TRIPULADO - VANT

Os VANTs, comumente conhecidos como drones, são sistemas aéreos autônomos ou controlados remotamente, caracterizados pela ausência de um piloto humano a bordo. Equipados com sensores sofisticados e microprocessadores, os VANTs operam de forma autônoma ou sob o controle de operadores remotos, oferecendo soluções versáteis e eficazes em uma ampla gama de aplicações, devido à sua capacidade de executar tarefas complexas com alta precisão e eficiência. Nesta seção, discutiremos a classificação, a arquitetura e as aplicações relacionadas aos VANTs.

A Figura 2 apresenta a classificação principal dos VANTs, englobando modelos de asa fixa, asa rotatória (como os multirrotores) e drones híbridos. Esta classificação fornece uma visão abrangente das diferenças estruturais e funcionais entre esses tipos de drones. Com o constante avanço tecnológico, a evolução desses modelos de drones permite um aperfeiçoamento significativo em suas capacidades operacionais, aumentando tanto a eficiência quanto

o potencial de aplicação desses sistemas.

Figura 2 – Classificação de Drones



Fonte: Baseado em NEWARK (2024)

Os VANTs de asa fixa possuem configuração semelhante à de aeronaves convencionais, implicando a necessidade de um controle mais elaborado e treinamento especializado. Esses dispositivos se destacam por sua elevada velocidade e capacidade de voo prolongado, embora apresentem limitações em termos de manobrabilidade, como a incapacidade de pairar ou realizar movimentos para trás (MOHSAN et al., 2022). Além disso, os VANTs de asa fixa são frequentemente utilizados em missões que demandam alta eficiência energética e grandes distâncias de cobertura, sendo particularmente vantajosos para aplicações em monitoramento e vigilância em larga escala.

Os VANTs de asa rotatória, representados na Figura 2, incluem configurações como quadricópteros, hexacópteros e octocópteros. Eles são particularmente populares devido à capacidade de decolagem e pouso verticais, facilidade de construção e custo relativamente baixo. São largamente empregados em atividades de imageamento e vigilância, e os quadricópteros, em especial, se destacam pela sua manobrabilidade e design simples (MOHSAN et al., 2022). A capacidade de se manter estacionários em pleno ar e de realizar movimentos precisos faz dos VANTs de asa rotatória uma ferramenta extremamente útil em aplicações como inspeções detalhadas de infraestruturas, filmagens aéreas e operações de resgate.

Os drones híbridos, também ilustrados na Figura 2, combinam as vantagens do voo planado e do voo vertical, conferindo-lhes uma versatilidade operacional única ao aliar os pontos fortes dos modelos de asa fixa e asa rotatória. Esses dispositivos híbridos conseguem realizar missões de longa distância mantendo uma boa manobrabilidade, sendo ideais para aplicações que exigem uma combinação de velocidade, alcance e capacidade de decolagem e pouso em locais restritos.

Cada tipo de VANT apresenta aplicações específicas de acordo com suas características técnicas, como tempo de voo, capacidade de carga útil e manobrabilidade. Por exemplo, os modelos de asa fixa são mais adequados para missões de longa duração, como mapeamento e inspeção, enquanto os modelos de asa rotatória são ideais para atividades que exigem alta agilidade e estabilidade estacionária, como a fotografia aérea (TAHIR et al., 2019). Com o avanço dos sistemas de controle autônomo, os VANTS têm ampliado suas aplicações em diversas áreas, desde inspeções industriais até o uso em operações de segurança pública.

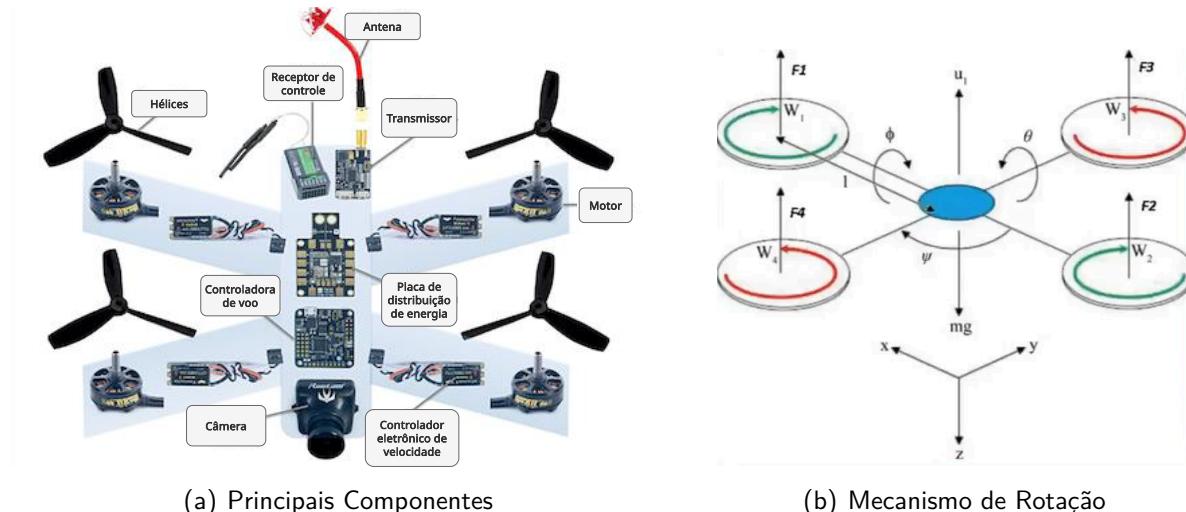
Adicionalmente, os VANTS podem ser classificados em termos de altitude operacional, diferenciando-se em plataformas de baixa altitude, Low Altitude Platform (LAP) e alta altitude, High Altitude Platform (HAP). LAPs são tipicamente utilizados para expansão de comunicação móvel e monitoramento ambiental, enquanto HAPs operam em altitudes mais elevadas, sendo empregados em atividades como vigilância de fronteiras e monitoramento climático (MOHSAN et al., 2022). As plataformas de alta altitude, em especial, têm um papel estratégico na coleta de dados em grande escala, proporcionando uma cobertura mais ampla e contínua para aplicações militares e científicas.

2.1.1 Arquitetura e Componentes

Os VANTS apresentam uma arquitetura complexa composta por diversos componentes fundamentais que garantem suas funcionalidades e aplicações. A Figura 3 mostra a arquitetura típica de um VANT multirotor, destacando tanto seus principais componentes quanto seu mecanismo de rotação.

Na Figura 3.a, observam-se os principais componentes de um VANT multirotor. As hélices geram a propulsão e a sustentação, movimentadas por motores que fornecem a força motriz. No centro do drone está a controladora de voo, o "cérebro" do dispositivo, responsável por manter a estabilidade e controlar o voo. A placa de distribuição de energia distribui a energia da bateria para os diversos componentes, sendo que a bateria, geralmente de Polímero de Lítio,

Figura 3 – Arquitetura e Componentes



Fonte: Baseado em NYAMUHUNGU (2022)

Lithium Polymer (LiPo), alimenta o sistema. Uma câmera frequentemente integrada permite a captura de imagens e vídeos. O controlador eletrônico de velocidade regula os motores, enquanto o receptor de controle capta sinais do controle remoto e um transmissor envia dados de telemetria para a estação de controle em terra.

A Figura 3.b representa o mecanismo de rotação de um quadricóptero, ilustrando como as forças geradas pelos quatro rotores (F_1, F_2, F_3, F_4) interagem para controlar o movimento do drone nos eixos de rotação (ϕ, θ, ψ) e gerar a força de sustentação. Esses eixos são essenciais para a manobrabilidade do drone, permitindo que ele mantenha estabilidade mesmo em condições adversas, como ventos fortes ou ambientes de operação restritos.

A arquitetura dos VANTs integra componentes essenciais para sua operação. Os controladores de voo são cruciais, requerendo calibração precisa para evitar falhas. A comunicação é garantida por controladores de rádio, que mantêm conectividade em distâncias consideráveis (AHMED et al., 2022). Ademais, VANTs modernos contam frequentemente com sensores e câmeras estabilizadas por gimbals, suportes estabilizadores, ampliando suas capacidades para vigilância, inspeção e monitoramento ambiental (AHMED et al., 2022). Sensores de detecção de obstáculos, como os sistemas de detecção e alcance de luz, Light Detection and Ranging (LIDAR), também têm se tornado comuns, proporcionando maior segurança durante o voo e permitindo que os VANTs operem de forma mais autônoma em ambientes complexos.

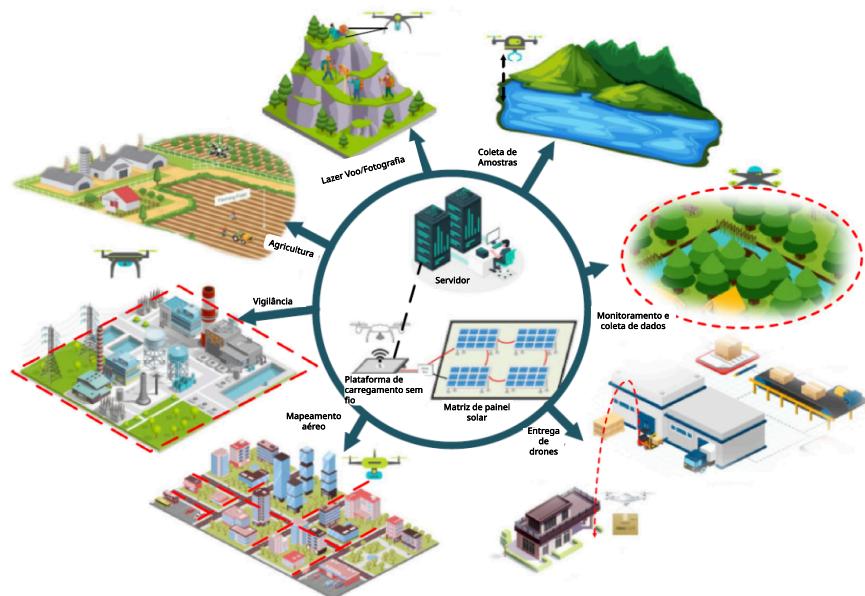
Estações de Controle em Terra, Ground Control Station (GCS) e plataformas de comunicação, embora não representadas, são elementos fundamentais que complementam o ecossistema

dos VANTs, permitindo operações remotas e a troca contínua de dados para tarefas em ambientes variados e complexos. As GCSs funcionam como centros de comando que facilitam o monitoramento em tempo real, o planejamento de missões e a tomada de decisões críticas durante as operações. Além disso, essas plataformas de comunicação garantem a integração eficaz dos VANTs com outras infraestruturas, proporcionando conectividade estável mesmo em locais remotos e adversos. A importância desses sistemas se torna ainda mais evidente em operações que demandam coordenação entre múltiplos VANTs, como missões de vigilância e resgate, onde a comunicação constante e precisa é crucial para o sucesso das atividades. A evolução tecnológica desses componentes está diretamente ligada ao aumento da autonomia e à eficiência operacional dos VANTs, permitindo que eles desempenhem um papel ainda mais significativo em diversas aplicações (AHMED et al., 2022).

2.1.2 Aplicabilidades e Benefícios

Os VANTs possuem ampla aplicação em diversos setores, evidenciando sua versatilidade e capacidade de inovação. A Figura 4 apresenta uma visão geral das múltiplas utilizações dos VANTs em áreas como agricultura, segurança, monitoramento urbano e muito mais.

Figura 4 – Aplicações de Drones



Fonte: Baseado em CHITTOOR; CHOKKALINGAM; MIHET-POPA (2021)

Na segurança e vigilância, VANTs são utilizados em missões militares e na detecção de

atividades ilegais, contribuindo para a prevenção de ameaças. Em situações de desastre, como ataques terroristas ou catástrofes naturais, os VANTs acessam áreas perigosas para coletar informações vitais e auxiliar no resgate, além de fornecer suprimentos médicos, o que é crucial para salvar vidas em momentos críticos (MOHSAN et al., 2022). Em muitas dessas aplicações, os VANTs operam como uma extensão das equipes humanas, aumentando a segurança dos profissionais ao evitar que eles precisem entrar em áreas de alto risco.

No sensoriamento remoto, os VANTs oferecem imagens de alta resolução essenciais para o monitoramento ambiental, detecção de doenças e mapeamento, contribuindo para a gestão sustentável dos recursos naturais. Na agricultura de precisão, VANTs monitoram culturas, realizam pulverização de pesticidas e coletam dados sobre o solo, aumentando a eficiência e produtividade (MOHSAN et al., 2022). Além disso, o uso de VANTs na agricultura tem se expandido para incluir aplicações como o plantio de sementes e a aplicação precisa de fertilizantes, ajudando a reduzir desperdícios e minimizando o impacto ambiental.

VANTs também facilitam a inspeção de infraestrutura, permitindo monitoramento detalhado de projetos e mapeamento 3D. Além disso, contribuem para o monitoramento de tráfego em tempo real, fornecendo uma solução mais econômica e eficaz do que dispositivos convencionais (MOHSAN et al., 2022). Esses dispositivos são estritamente necessários em ambientes urbanos, onde o acesso pode ser limitado e a eficiência das inspeções tradicionais pode ser comprometida devido à complexidade das estruturas.

No contexto de cidades inteligentes, VANTs funcionam como plataformas flexíveis para implantação de estações-base aéreas, melhorando a eficiência de redes 5G e atuando como dispositivos conectados no ecossistema IoT. Eles são explorados para transferência de energia e informação sem fio, suportando o desenvolvimento de redes sustentáveis (MOHSAN et al., 2022; LABIB et al., 2021). Além disso, em cidades inteligentes, os VANTs podem ser utilizados para monitoramento ambiental em tempo real, ajudando a detectar níveis de poluição, identificar áreas de congestionamento e até mesmo prestar suporte em emergências, garantindo uma resposta rápida e eficiente.

Em síntese, os VANTs oferecem soluções inovadoras e eficientes em segurança, resposta a desastres, agricultura, inspeção de infraestrutura e cidades inteligentes, contribuindo significativamente para a modernização de diferentes setores. Esses dispositivos têm se tornado ferramentas essenciais, não apenas para melhorar a eficiência de tarefas tradicionais, mas também para viabilizar novas abordagens e soluções que antes eram impraticáveis devido a limitações tecnológicas ou de segurança.

2.2 DEPENDABILIDADE

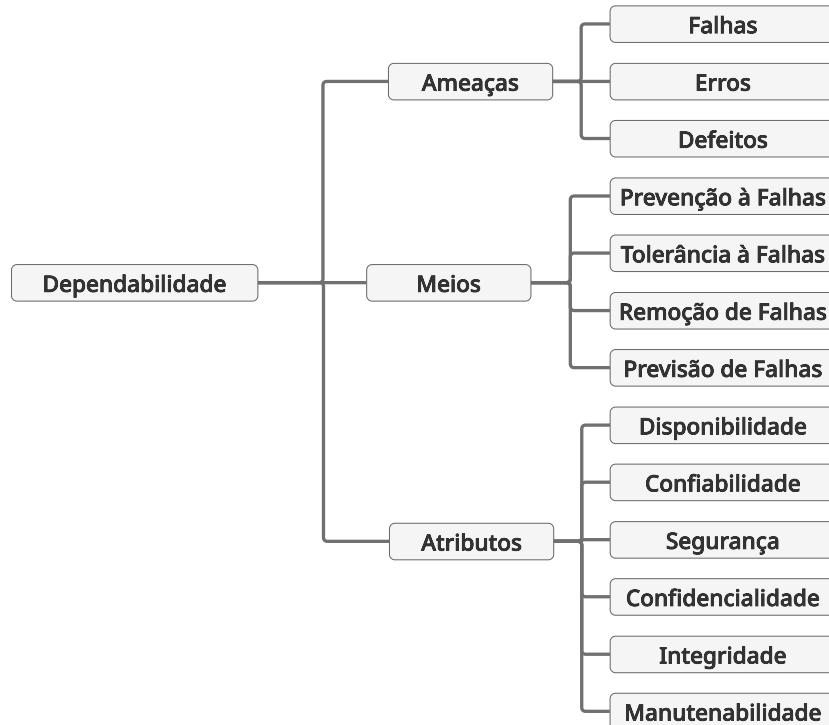
A confiabilidade em sistemas computacionais, também conhecida como dependabilidade, é um conceito fundamental que denota a capacidade de um sistema contratado de entregar seu serviço pretendido consistentemente. Este conceito assume particular importância quando um ou mais componentes do sistema podem experimentar falhas, potencialmente interrompendo o serviço pretendido. A dependabilidade está intrinsecamente ligada à confiabilidade, que quantifica a probabilidade de um sistema fornecer seu serviço sem falhas até um tempo especificado t (AVIZIENIS et al., 2004). Especificamente, se o sistema inicia a operação no tempo 0, sua confiabilidade no tempo t representa a probabilidade de operação ininterrupta durante o intervalo de tempo $(0, t)$ (TRIVEDI, 2008; MACIEL, 2023).

Para melhor compreender este conceito complexo, é útil visualizá-lo através da Árvore de Dependabilidade, baseada no trabalho de AVIZIENIS et al. (2001). Esta representação visual oferece uma estrutura organizada para compreender os elementos que compõem a dependabilidade de um sistema, decompondo-o em três componentes principais: ameaças, meios e atributos. As ameaças englobam falhas, erros e defeitos que podem comprometer o funcionamento do sistema. Os meios representam as estratégias para alcançar a dependabilidade, incluindo prevenção, tolerância, remoção e previsão de falhas. Os atributos são as características desejáveis de um sistema confiável, como disponibilidade, confiabilidade, segurança, confidencialidade, integridade e manutenabilidade (AVIZIENIS et al., 2001).

Cada um desses atributos desempenha um papel crucial na confiabilidade geral do sistema. A disponibilidade refere-se à prontidão do sistema para o serviço correto, enquanto a confiabilidade está relacionada à continuidade desse serviço. A segurança busca evitar consequências graves, a confidencialidade protege contra divulgação não autorizada de informações, a integridade previne alterações indevidas no estado do sistema, e a manutenabilidade permite que o sistema passe por reparos e modificações quando necessário (AVIZIENIS et al., 2001).

Uma propriedade crucial da dependabilidade é a disponibilidade em estado estacionário, que caracteriza a capacidade de um sistema de continuar funcionando mesmo na presença de falhas e reparos subsequentes (TRIVEDI, 2008). O cálculo da disponibilidade pode ser feito usando o Tempo Médio para Falha, Mean Time to Failure (MTTF) e o Tempo Médio para Reparo, Mean Time to Repair (MTTR), como mostrado na Equação 2.1:

Figura 5 – Árvore de Dependabilidade



Fonte: Baseado em AVIZIENIS et al. (2001)

$$A = \frac{MTTF}{MTTF + MTTR}. \quad (2.1)$$

A integral de confiabilidade fornece o MTTF do sistema em função do tempo (Eq. 2.2). Em contraste, o MTTR é usado para atingir o nível desejado de disponibilidade considerando a reparação do sistema (Eq. 2.3). Disponibilidade (A) e indisponibilidade ($UA = 1 - A$) estão relacionadas conforme mostrado na Equação 2.4.

$$MTTF = \int_0^t R(t)dt. \quad (2.2)$$

$$MTTR = \int_0^\infty (1 - M(t))dt. \quad (2.3)$$

Onde $M(t)$ define a probabilidade que o sistema S vai ser reparado no tempo t (definido como manutenabilidade).

Além disso, o tempo de inatividade (Downtime - DT) pode ser definido como o tempo total durante o qual um sistema está indisponível:

$$DT = MTTR \times (1 - A). \quad (2.4)$$

Na modelagem de desempenho e confiabilidade, as variáveis aleatórias exponenciais são amplamente adotadas devido à sua capacidade de representar certos fenômenos e sua tratabilidade matemática, particularmente sua propriedade de falta de memória. No entanto, quando a distribuição exponencial é inadequada para modelar um sistema, as distribuições de fase, Phase-type (PH), incluindo as distribuições Erlang, hipoexponencial e hiperexponencial, podem oferecer alternativas adequadas. Essas distribuições são essenciais para representar distribuições de probabilidade complexas usando apenas dados de média e desvio padrão (MACIEL, 2023b). A distribuição de Erlang é um caso particular da distribuição gama com um parâmetro de forma $\gamma > 1$, $\gamma \in \mathbb{N}$, e taxa λ . As distribuições PH oferecem uma abordagem controlada para relaxar a propriedade de ausência de memória e manter a complexidade de avaliação sob controle, observando o histórico dos processos através de fases exponenciais do passado e aumentando o poder de modelagem das distribuições exponenciais.

É importante compreender que a dependabilidade de um sistema não é um conceito absoluto, mas deve ser interpretada em um sentido probabilístico. Os sistemas, por sua natureza complexa, não estão completamente livres de falhas. Esta perspectiva realista é útil para entender e avaliar o desempenho dos sistemas em condições operacionais reais.

As quatro técnicas principais para alcançar a dependabilidade, representadas como "Meios" na árvore de dependabilidade, trabalham em conjunto para fortalecer a dependabilidade do sistema. A prevenção de falhas busca minimizar a ocorrência de problemas, a tolerância a falhas permite que o sistema continue operando mesmo na presença de falhas, a remoção de falhas foca na identificação e correção de problemas existentes, e a previsão de falhas antecipa potenciais problemas futuros (AVIZIENIS et al., 2001; AVIZIENIS et al., 2004).

Complementando a análise de confiabilidade, a modelagem de desempenho é uma abordagem estruturada que visa estimar as principais métricas de desempenho de um sistema (KLEINROCK, 1975; HAVERKORT, 2001). Uma dessas métricas é a taxa de transferência (*throughput*), que quantifica o número de operações concluídas num prazo específico:

$$TP = \pi(ibp > 0) \times \mu, \quad (2.5)$$

onde $\pi(ibp > 0)$ é a probabilidade de haver itens sendo processados (*ibp*) no sistema, e μ é a taxa de serviço.

Outras métricas importantes incluem o número médio de itens, Mean Number of Items (MNI) em um sistema:

$$MNI = \sum_{i=1}^n i \cdot \pi(i), \quad (2.6)$$

onde $\pi(i)$ é a probabilidade de haver i itens no sistema, e n é o número total de possíveis estados no sistema.

Já a Utilização (U) de um recurso, é definida como:

$$U = \pi(ibp > 0), \quad (2.7)$$

onde $\pi(ibp > 0)$ é a probabilidade de haver itens sendo processados pelo recurso.

Enquanto a modelagem de desempenho foca nas métricas de eficiência do sistema, a modelagem de confiabilidade concentra-se na compreensão de como as mudanças na estrutura de um sistema, muitas vezes devido a falhas, afetam a disponibilidade geral do sistema (MELO et al., 2015). A integração desses dois aspectos levou ao desenvolvimento do conceito de **performabilidade**.

Em 1980, Meyer MEYER (1980) introduziu o conceito de avaliação de **performabilidade**, que avalia a qualidade geral de um sistema considerando simultaneamente seus aspectos de desempenho e confiabilidade. Essa abordagem emprega uma medida composta que quantifica como o desempenho do sistema se degrada quando ocorrem falhas. A avaliação de **performabilidade** de sistemas refere-se à avaliação da capacidade de um sistema de entregar seu desempenho pretendido na presença de falhas e condições operacionais variáveis, integrando métricas de desempenho e dependabilidade.

A **performabilidade** é, portanto, um fator crucial na obtenção de uma avaliação abrangente do sistema, considerando a potencial ocorrência de falhas e seu impacto no desempenho. Avaliar apenas o desempenho e desconsiderar a confiabilidade pode ser excessivamente simplista, assumindo que o sistema opera em perfeito estado, o que raramente é o caso em ambientes reais.

Em síntese, a árvore de dependabilidade, juntamente com os conceitos associados de distribuições de fase e métricas de desempenho e confiabilidade, fornece uma estrutura visual e conceitual abrangente para compreender e analisar a confiabilidade em sistemas computacionais. Esta abordagem holística evidencia a complexidade e as inter-relações entre os diversos

aspectos da confiabilidade, servindo como uma ferramenta valiosa para projetistas e analistas de sistemas. Ao utilizar esta estrutura e considerar aspectos como performabilidade, os profissionais podem desenvolver abordagens mais abrangentes e eficazes na busca por sistemas mais robustos, seguros e confiáveis, essenciais em um mundo cada vez mais dependente de tecnologias computacionais.

2.3 MODELOS ESTOCÁSTICOS

Modelos estocásticos são ferramentas essenciais na avaliação do desempenho, confiabilidade e disponibilidade de sistemas computacionais. Esses modelos incorporam aleatoriedade e incerteza diretamente na análise, permitindo uma compreensão mais abrangente dos comportamentos do sistema sob várias condições operacionais. Entre as técnicas de modelagem estocástica, as Cadeias de Markov se destacam por sua capacidade de descrever o funcionamento do sistema com base em um conjunto de estados e transições, que podem representar eventos de falha e reparo de um sistema ou componente.

As cadeias de Markov são particularmente vantajosas em relação aos Diagramas de Blocos de Confiabilidade, RBD, quando se trata de descrever propriedades dinâmicas dos sistemas (BOLCH et al., 2006). Cada transição em uma cadeia de Markov representa um processo estocástico $X(t)$, onde $t \in T$ é um conjunto de variáveis aleatórias definidas sobre o mesmo espaço de probabilidades, e capazes de assumir valores no espaço de estados $S_i \in S$ (CASSANDRAS; LAFORTUNE, 2008).

2.3.1 Cadeias de Markov de Tempo Contínuo - CTMC

O conjunto T ao qual a variável pertence determina a natureza do processo. Se T for discreto, com $t = 1, 2, 3, \dots$, o processo é denominado de parâmetro discreto ou tempo discreto. Por outro lado, se T for um conjunto contínuo, tem-se um processo de parâmetro contínuo ou tempo contínuo. Estes processos assumem distribuições geométricas (Cadeia de Markov em Tempo Discreto, Discrete Time Markov Chain (DTMC)) ou exponenciais (CTMC), respectivamente (SOUZA et al., 2009; MACIEL, 2023a).

Um processo estocástico é classificado como um processo de Markov se, para todo $t_0 < t_1 < \dots < t_n < t_{n+1}$ e para todo $X(t_0), X(t_1), X(t_2), \dots, X(t_n), X(t_{n+1})$, a distribuição condicional de $X(t_{n+1})$ depende somente do último valor anterior $X(t_n)$ e não dos valores que o antecedem

$X(t_0), X(t_1), \dots, X(t_{n-1})$. Matematicamente, isso pode ser expresso como:

$$P(X_{n+1} = s_{n+1} | X_n = s_n, X_{n-1} = s_{n-1}, \dots, X_0 = s_0) = P(X_{n+1} = s_{n+1} | X_n = s_n) \quad (2.8)$$

para qualquer número real $X_0, X_1, X_2, \dots, X_n, X_{n+1}$ (BOLCH et al., 2006).

Esta característica é também conhecida como ausência de memória, e é uma propriedade fundamental das Cadeias de Markov. Nas CTMCs, as transições entre estados podem ocorrer a qualquer momento, tornando-as particularmente úteis para modelar sistemas onde os eventos ocorrem de forma contínua ao longo do tempo.

Formalmente, uma CTMC é um processo estocástico $\{X(t), t \geq 0\}$ que satisfaz a propriedade de Markov para todo $t_0 < t_1 < \dots < t_n < t_{n+1}$:

$$P(X(t_{n+1}) = j | X(t_n) = i, X(t_{n-1}) = i_{n-1}, \dots, X(t_0) = i_0) = P(X(t_{n+1}) = j | X(t_n) = i) \quad (2.9)$$

As CTMCs são caracterizadas por uma matriz de taxa de transição Q , onde q_{ij} representa a taxa de transição do estado i para o estado j . A matriz Q tem a seguinte forma:

$$Q = \begin{pmatrix} q_{11} & q_{12} & \cdots & q_{1n} \\ q_{21} & q_{22} & \cdots & q_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ q_{n1} & q_{n2} & \cdots & q_{nn} \end{pmatrix} \quad (2.10)$$

onde $q_{ii} = -\sum_{j \neq i} q_{ij}$, garantindo que a soma de cada linha seja zero.

A análise de CTMCs permite obter métricas importantes como probabilidades de estado estacionário, tempo médio de primeira passagem, e medidas de desempenho e confiabilidade do sistema. Para resolver uma CTMC e obter estas métricas, geralmente se utiliza a equação de Chapman-Kolmogorov em sua forma diferencial:

$$\frac{d\pi(t)}{dt} = \pi(t)Q \quad (2.11)$$

onde $\pi(t)$ é o vetor de probabilidades de estado no tempo t .

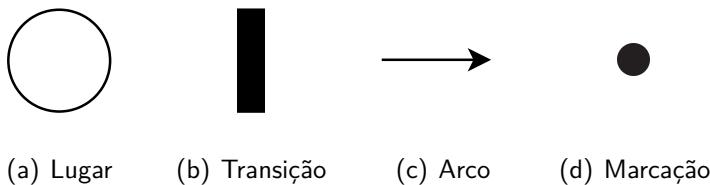
Para a resolução do sistema, define-se a condição inicial $\pi(0) = \pi_0(0)$, onde $\pi_0(0)$ representa o vetor de probabilidades de estado no instante inicial $t = 0$, descrevendo a distribuição inicial dos estados do sistema.

As Cadeias de Markov de Tempo Contínuo oferecem um poderoso *framework* para a análise de sistemas estocásticos complexos, permitindo aos engenheiros e pesquisadores modelar e analisar o comportamento de sistemas computacionais sob condições de incerteza e variabilidade. Sua aplicação abrange desde a avaliação de desempenho de redes de computadores até a análise de confiabilidade de sistemas de missão crítica, tornando-as uma ferramenta indispensável no campo da engenharia de sistemas e ciência da computação.

2.3.2 Redes de Petri Estocásticas - SPN

As Redes de Petri, Petri Nets (PN), são uma ferramenta de modelagem para sistemas complexos, concorrentes e assíncronos. Desenvolvidas por Carl Adam Petri em 1962, estas redes têm sido utilizadas em diversas áreas, incluindo engenharia de software, análise de processos de negócios e sistemas de manufatura. A estrutura básica das redes de Petri inclui componentes conhecidos como lugares, transições, arcos e marcações, como ilustrado na Figura 6.

Figura 6 – Principais Componentes de uma Rede de Petri

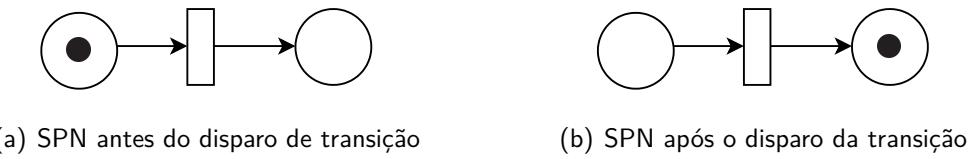


Fonte: Baseado em MELO (2016)

Os lugares, representados por círculos, podem conter tokens (marcações), e a distribuição de tokens pelos lugares representa o estado do sistema em um determinado momento. As transições, representadas por retângulos ou barras, são responsáveis pelo movimento dos tokens entre os lugares. Este movimento é governado por regras de habilitação e disparo que ditam o fluxo dentro da rede. Os arcos conectam lugares a transições e vice-versa, indicando o caminho que os tokens podem seguir.

A Figura 7 apresenta um exemplo de uma rede de Petri antes e após o disparo de uma transição. Na Figura 7(a), vemos o estado inicial da rede, com tokens distribuídos em determinados lugares. A Figura 7(b) mostra o estado após o disparo da transição, onde os tokens foram movidos de acordo com as regras da rede. Os disparos de transições ou a ocorrência de ações em uma rede de Petri são possíveis quando o número de recursos/marcações é suficiente.

Figura 7 – Exemplo de uma Rede de Petri



Fonte: Baseado em MELO (2016)

ente no lugar que as antecede (MACIEL; LINS; CUNHA, 1996). Este mecanismo permite modelar situações de concorrência e sincronização.

De acordo com (MURATA, 1989), uma rede de Petri pode ser formalmente definida através de uma 5-tupla, do tipo $PN = (P, T, F, W, M_0)$, onde:

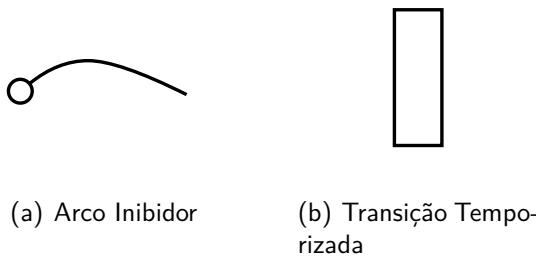
- $P = (p_1, p_2, \dots, p_n)$ é um conjunto finito de lugares,
- $T = (t_1, t_2, \dots, t_m)$ é um conjunto finito de transições,
- $F \subseteq (P \times T) \cup (T \times P)$ é um conjunto de arcos,
- $W : F \rightarrow \{1, 2, 3, \dots\}$ é a função de peso,
- $M_0 : P \rightarrow \{0, 1, 2, 3, \dots\}$ são as marcações iniciais.

Esta definição matemática fornece uma base para a análise e verificação de propriedades dos sistemas modelados. Por exemplo, é possível verificar se um sistema pode entrar em *deadlock*, se existem estados inalcançáveis, ou se certas condições de segurança são mantidas.

O avanço no estudo das redes de Petri proporcionou uma evolução em seu poder de representação. Uma extensão útil são as SPNs, que permitem descrever sistemas assíncronos, temporizados, concorrentes e não-determinísticos (GERMAN, 2000). As SPNs introduzem elementos probabilísticos, permitindo modelar sistemas com comportamento aleatório ou incerto.

A Figura 8 mostra componentes adicionais para uma rede de Petri estocástica: o arco inibidor e a transição temporizada. Arcos inibidores, representados por uma linha terminada em um círculo, determinam se um dado local possui ou não marcações. Eles permitem modelar situações onde a ausência de recursos é uma condição para uma ação. As transições temporizadas têm seu tempo de disparo pré-estabelecido e baseado em uma distribuição de probabilidade (MELO et al., 2015). Isso permite modelar ações que levam tempo para serem concluídas ou que ocorrem em intervalos aleatórios.

Figura 8 – Componentes Adicionais para uma Rede de Petri Estocástica



Fonte: Baseado em MELO (2016)

As **SPNs** são uma poderosa extensão das redes de Petri tradicionais, projetadas para modelar sistemas complexos onde a aleatoriedade e os tempos de transição são fundamentais (SYMONS, 1989; NATKIN, 1980; MOLLOY, 1981). Enquanto as redes de Petri clássicas são eficientes para descrever a lógica de processos concorrentes, elas não são suficientes para modelar aspectos temporais e probabilísticos. Para resolver isso, as SPNs introduzem transições temporizadas com distribuições estocásticas, permitindo que o tempo de disparo de uma transição siga uma distribuição de probabilidade, como a exponencial, a determinística ou outras distribuições genéricas. Essa abordagem é particularmente útil para modelar e analisar sistemas de filas, redes de comunicação, e infraestruturas de computação, onde eventos ocorrem de forma aleatória ao longo do tempo.

Várias extensões foram desenvolvidos a partir do modelo básico das SPNs para aprimorar ainda mais suas capacidades de modelagem. Entre as extensões mais importantes estão as **Redes de Petri Estocásticas Generalizadas, Generalized Stochastic Petri Nets (GSPN)** (MARSAN et al., 1998), que adicionam transições imediatas para capturar eventos que ocorrem instantaneamente, e as **Redes de Petri Estocásticas Determinísticas, Deterministic Stochastic Petri Nets (DSPN)** (LINDEMANN, 1998), que incorporam transições com tempos determinísticos. Essas extensões permitem uma modelagem mais precisa de sistemas que possuem comportamentos estocásticos, mas também eventos determinísticos ou de disparo imediato. Além disso, existem outras variantes, como as **Redes de Petri Determinísticas e Estocásticas, Deterministic and Stochastic Petri Nets (eDSPN)** (GERMAN, 2000; GERMAN; LINDEMANN, 1994), que ampliam ainda mais a gama de sistemas que podem ser analisados com precisão por meio de SPNs. Essas extensões tornam as SPNs uma ferramenta robusta para a análise de desempenho, confiabilidade e disponibilidade de sistemas complexos.

A definição de uma SPN pode ser descrita formalmente como um conjunto de elementos que estendem a definição de uma rede de Petri tradicional com comportamentos estocásticos. Uma SPN é representado pela tupla:

$$\text{SPN} = (P, T, I, O, H, M_0, \text{Atts})$$

Onde:

- **P**: Conjunto finito de lugares ($P = \{p_1, p_2, \dots, p_n\}$).
- **T**: Conjunto finito de transições ($T = \{t_1, t_2, \dots, t_m\}$), que é dividido em:
 - T_{im} : Transições imediatas.
 - T_{exp} : Transições com distribuições exponenciais.
 - T_{det} : Transições determinísticas.
 - T_g : Transições com distribuições genéricas.

Assim, $T = T_{im} \cup T_{exp} \cup T_{det} \cup T_g$.

- **I**: Matriz de entrada que define as conexões entre lugares e transições. Cada elemento $i_{p,t}$ representa o peso do arco de entrada do lugar p para a transição t , e pode ser dependente da marcação atual:

$$I = (i_{p,t})_{|P| \times |T|}, \quad i_{p,t} : MD \times RS_{\text{SPN}} \rightarrow \mathbb{N}$$

onde $MD = \{\text{verdadeiro}, \text{falso}\}$, indicando se o arco é dependente da marcação.

- **O**: Matriz de saída que define as conexões entre transições e lugares. Cada elemento $o_{p,t}$ representa o peso do arco de saída da transição t para o lugar p , que também pode depender da marcação:

$$O = (o_{p,t})_{|P| \times |T|}, \quad o_{p,t} : MD \times RS_{\text{SPN}} \rightarrow \mathbb{N}$$

- **H**: Matriz de arcos inibidores, onde $h_{p,t}$ inibe a transição t se o número de tokens no lugar p for maior ou igual a $h_{p,t}$:

$$H = (h_{p,t})_{|P| \times |T|}, \quad h_{p,t} : MD \times RS_{\text{SPN}} \rightarrow \mathbb{N}$$

- M_0 : A marcação inicial da rede, que é um vetor que descreve a quantidade inicial de tokens em cada lugar p :

$$M_0 = (m_p)_{|P|}$$

- **Atts**: O conjunto de atributos associados às transições, definidos como:

$$\text{Atts} = (\Pi, \text{Dist}, \text{MDF}, W, G, \text{Policy}, \text{Concurrency})$$

- $\Pi : T \rightarrow \mathbb{N}$: Atribui uma prioridade às transições.
- $\text{Dist} : T_{exp} \cup T_g \rightarrow F$: Função que atribui uma distribuição de probabilidade não negativa para transições temporizadas.
- $\text{MDF} : T \rightarrow MD$: Define se a distribuição de probabilidade de uma transição depende da marcação.
- $W : T_{exp} \cup T_{det} \cup T_{im} \rightarrow \mathbb{R}^+$: Atribui taxas (distribuições exponenciais), atrasos (transições determinísticas), ou pesos (transições imediatas) às transições.
- $G : T \rightarrow \mathbb{N}^{|P|}$: Expressão de guarda que define uma condição booleana para que a transição seja habilitada.
- $\text{Policy} : T \rightarrow \{\text{prd}, \text{prs}\}$: Define a política de memória (reiniciar ou continuar o temporizador de transições).
- $\text{Concurrency} : T - T_{im} \rightarrow \{\text{sss}, \text{iss}\}$: Define a semântica de concorrência, onde **SSS** denota semântica de servidor único, Single Server Semantics (SSS) e **ISS** denota semântica de servidor infinito, Infinite Server Semantics (ISS).

Regras de habilitação e disparo:

Uma transição t_i é habilitada em uma marcação M se:

$$M \geq I_{\cdot, t_i} \wedge M < H_{\cdot, t_i} \wedge G(t_i) = \text{verdadeiro}$$

onde I_{\cdot, t_i} é o vetor de entradas para t_i e H_{\cdot, t_i} é o vetor de inibidores para t_i . O disparo de uma

transição habilitada t_i em uma marcação M leva a uma nova marcação M' , dada por:

$$M' = M - I_{\cdot, t_i} + O_{\cdot, t_i}$$

Esta formulação matemática permite que SPNs sejam usados para modelar sistemas estocásticos com comportamentos complexos, incorporando não apenas a dinâmica de redes de Petri tradicionais, mas também a estocasticidade e características temporais (MACIEL, 2023a)

2.4 ANÁLISE DE SENSIBILIDADE

A análise de sensibilidade é uma técnica essencial para avaliar o impacto das variações nos parâmetros de entrada sobre a disponibilidade de um sistema. Diferentes abordagens podem ser aplicadas, como a Análise de Sensibilidade Diferencial, Medidas de Sensibilidade Uma por Uma, o Método do Desvio Relativo, a Taxa de Desvio Relativo, o Coeficiente de Correlação Parcial de Postos e o Índice de Sensibilidade, Sensitivity Index (SI) (HAMBY, 1995). Cada uma dessas técnicas oferece uma perspectiva distinta sobre como as variações nos parâmetros de entrada afetam a saída do modelo. Neste estudo, utilizamos o SI, uma métrica quantitativa que mede o impacto das variações de um parâmetro de entrada y sobre a disponibilidade do sistema. O SI expressa esse impacto como uma diferença percentual relativa, o que permite identificar os parâmetros que possuem maior influência na estabilidade e no desempenho do sistema, possibilitando assim a priorização de ajustes e melhorias nos parâmetros críticos para a disponibilidade.

A Equação 2.12 define o índice de sensibilidade, Sensitivity Index (**SI**), que expressa esse impacto como uma diferença percentual relativa e é definido pela fórmula:

$$S_{x_i}(f(x_i)) = \frac{\max_{f(x_i)} - \min_{f(x_i)}}{\max_{f(x_i)}} \quad (2.12)$$

onde:

- $\max_{f(x_i)}$ é o valor máximo do parâmetro x_i obtido ao variar o parâmetro dentro do seu intervalo permitido;
- $\min_{f(x_i)}$ é o valor mínimo correspondente de x_i .

Esse índice de sensibilidade fornece uma medida da proporção da variação da saída em relação ao valor máximo de x_i , destacando a sensibilidade do parâmetro x_i às flutuações do parâmetro analisado. Durante o cálculo de $S_{x_i}(f(x_i))$, todos os outros parâmetros do modelo permanecem constantes, garantindo que a análise isolada do impacto do parâmetro x_i seja precisa (FRANK; ESLAMI, 1980). Essa abordagem é particularmente útil para melhorar

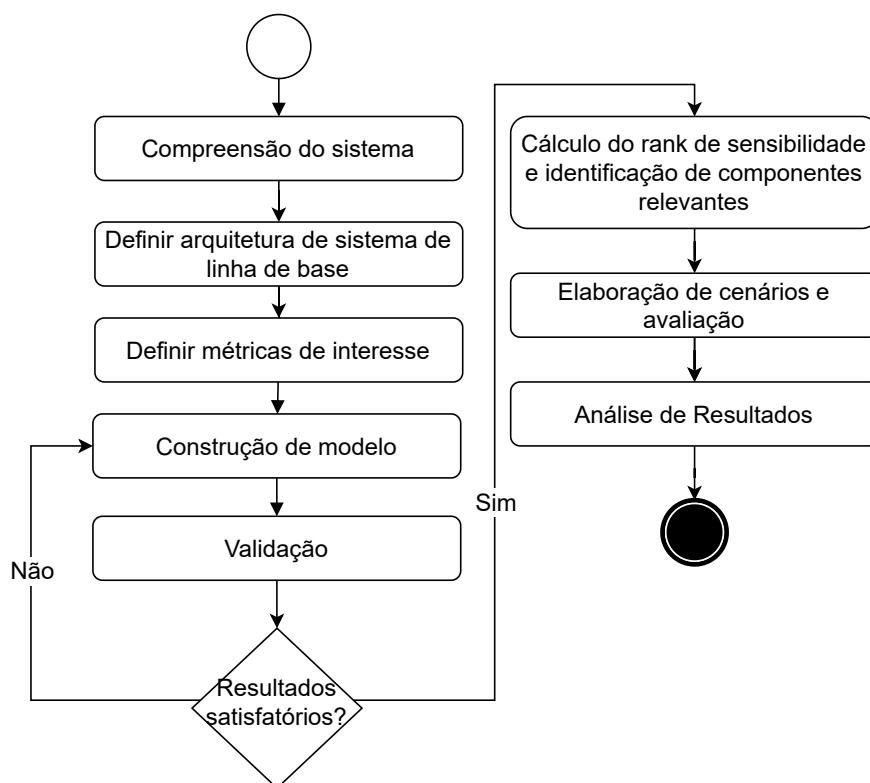
a previsibilidade do comportamento do sistema, já que permite uma avaliação detalhada da robustez em relação às variações de x_i , auxiliando no planejamento preciso das condições operacionais.

A escolha do Índice de Sensibilidade neste estudo foi motivada por sua simplicidade e facilidade de implementação, especialmente na linguagem de scripts da ferramenta Mercury (MACIEL et al., 2017). A simplicidade da fórmula de $S_{x_i}(f(x_i))$ facilita sua implementação prática, permitindo uma análise de sensibilidade eficiente e rápida. Isso é particularmente benéfico em cenários onde análises ágeis e precisas são necessárias para tomar decisões informadas, tornando o SI uma ferramenta valiosa para otimizar a disponibilidade e a confiabilidade dos sistemas analisados.

3 METODOLOGIA

A metodologia utilizada neste trabalho visa garantir uma abordagem sistemática para o desenvolvimento e a validação de um sistema de vigilância baseado em VANTs. O capítulo descreve cada uma das etapas envolvidas no processo, desde a compreensão inicial do sistema até a definição das métricas de interesse, construção e validação do modelo, e análise de sensibilidade. As etapas são delineadas para fornecer uma visão clara de como os componentes do sistema interagem para garantir a performance e a disponibilidade do sistema de vigilância. A abordagem também inclui uma análise detalhada dos resultados, possibilitando a identificação de áreas de melhoria e a otimização dos recursos envolvidos.

Figura 9 – Visão Geral da Metodologia Adotada para Avaliação de Sistemas de Vigilância por Drones.



Fonte: Elaborado pelo Autor (2024)

A Figura 9 apresenta uma visão geral da metodologia adotada para a avaliação do sistema de vigilância com drones, destacando cada etapa do processo, desde a compreensão do sistema até a análise dos resultados e a identificação dos componentes relevantes. Essa representação visual facilita o entendimento das etapas sequenciais e das relações entre elas, proporcionando

uma visão clara do fluxo de trabalho empregado para garantir a eficiência e confiabilidade do sistema.

O primeiro passo para a execução deste trabalho foi realizar uma revisão da literatura sobre sistemas de vigilância baseados em drones. O objetivo dessa etapa foi identificar as principais abordagens utilizadas em diferentes cenários de vigilância e como as características dos drones e câmeras influenciam na eficiência dos sistemas. Estudos sobre a confiabilidade e a disponibilidade de drones em missões críticas foram analisados para embasar o desenvolvimento dos modelos utilizado neste trabalho. Dentre os principais trabalhos revisados, destacaram-se aqueles que abordam o uso de drones em áreas abertas para monitoramento contínuo, além de estudos que utilizam métricas como redundância de baterias e drones para garantir a alta disponibilidade do sistema.

- **Compreensão do Sistema:** A primeira etapa da metodologia consistiu no estudo aprofundado do sistema, onde foi realizada uma análise detalhada dos componentes envolvidos, como a estrutura dos drones, características das câmeras, capacidades de bateria, sensores, limitações operacionais e gerência de energia. Foram coletadas informações de fabricantes e de fontes acadêmicas para entender o comportamento esperado do sistema de vigilância. Esse entendimento serviu como base para a definição dos requisitos que guiariam as etapas subsequentes, garantindo uma compreensão abrangente do sistema antes de prosseguir com a modelagem e análise.
- **Definir Arquitetura de Sistema Base:** Na etapa de definição da arquitetura do sistema de linha de base, foi estabelecida a arquitetura para um sistema de vigilância com drone e também o modelo utilizado para teste. Esta etapa incluiu a definição do número de drones, características das câmeras (resolução, campo de visão), quantidade de baterias, além do layout da área de vigilância a ser monitorada. Foi utilizado o drone DJI Mavic Pro, que possui especificações adequadas para os testes em campo aberto. O drone está equipado com uma câmera de resolução Full HD, permitindo a captura de imagens de qualidade para vigilância. Além disso, foram utilizadas quatro baterias extras, cada uma com uma autonomia estimada de 25 minutos de voo. No entanto, durante o experimento, algumas baterias apresentaram variações na carga inicial, influenciando o desempenho do drone em determinadas rondas.

A área escolhida para o experimento foi um terreno aberto e plano, adequado para simular o funcionamento de um sistema de vigilância. A área foi mapeada para o drone

realizar um padrão de voo específico, cobrindo toda a superfície eficientemente. Esta arquitetura base serviu como ponto de referência para o desenvolvimento dos modelos de simulação e para avaliação dos requisitos necessários para garantir a operação do sistema.

- **Definir Métricas de Interesse:** Na terceira etapa, realizou-se a definição das métricas de interesse para avaliar o desempenho do sistema de vigilância. As principais métricas incluem:

- Disponibilidade estacionária: reflete a capacidade do sistema de se manter operacional;
- Confiabilidade: indica a probabilidade de o sistema funcionar sem falhas por um determinado período;
- Tempo médio de cobertura, Cov_{time} , da área de vigilância;
- Número médio de itens no sistema (MNI);
- Utilização dos recursos (U): representa o uso efetivo dos componentes do sistema.

Essas métricas foram importantes para analisar o impacto das diferentes configurações do sistema, avaliar o nível de serviço oferecido e identificar possíveis áreas de melhoria.

- **Construção de Modelo:** A construção do modelo estocástico foi realizada utilizando inicialmente um modelo CTMC para análise de melhorias de tempos médios e posteriormente modelos SPN para representar as operações e interações com redundâncias e desempenho do sistema de vigilância. Este tipo de modelagem foi escolhido devido à sua capacidade de representar sistemas complexos, descrevendo comportamentos dinâmicos como falhas, reparos, trocas de baterias e movimentação dos drones. O modelo foi dividido em duas partes principais: uma dedicada à disponibilidade, avaliando o comportamento do sistema em caso de falhas e reparos, e outra voltada para a performance, medindo métricas como o número de rondas de vigilância por hora. Foram utilizadas transições temporizadas exponenciais e redes do tipo Erlang para representar o fluxo de estados do sistema, considerando fatores como autonomia de voo, tempos de carga e descarga das baterias e o impacto de redundâncias.
- **Validação:** Na quinta etapa, realizou-se a validação do modelo, que visa garantir que o comportamento do modelo simulado seja consistente com o sistema real. Um drone

comercial, como o DJI Mavic Pro, foi utilizado para validar o modelo, comparando dados coletados do drone real com os resultados do modelo. As métricas utilizadas incluíram tempo de voo, tempo de carga da bateria e a cobertura da área de vigilância. Para garantir a precisão da validação, utilizou-se o método bootstrap para calcular intervalos de confiança para os tempos médios de cobertura, a fim de verificar se o modelo reflete adequadamente as condições reais observadas.

Dentre as variáveis coletadas, os dados de maior interesse foram os relacionados à porcentagem de bateria, coordenadas GPS, altura de voo, velocidade e tempo de voo. Com base nessas variáveis, foi possível realizar a análise da performance do drone em relação ao número de rondas completas que ele conseguia realizar com cada carga de bateria. Uma ronda foi definida como o trajeto completo de ida e volta, cobrindo toda a área de vigilância.

- **Resultados satisfatórios? (Avaliação dos Resultados):** Com os dados coletados, o modelo de cobertura foi refinado de modo a ajustar os tempos médios observados com o intervalo de confiança estimado. O objetivo desse ajuste foi garantir que o modelo de cobertura fosse uma representação precisa do comportamento real do drone durante o processo de vigilância. Caso os resultados não fossem satisfatórios, o modelo seria ajustado e a simulação refeita até que o desempenho desejado fosse atingido. Este processo iterativo de ajuste e refinamento visou garantir que o modelo simulasse adequadamente as características importantes do sistema, e que as decisões tomadas a partir dos resultados fossem embasadas em simulações precisas e representativas do cenário real.
- **Cálculo do Rank de Sensibilidade e Identificação de Componentes Relevantes:** Uma vez que o modelo foi validado, procedeu-se com a análise de sensibilidade e identificação dos componentes relevantes. O objetivo desta etapa foi determinar quais variáveis do sistema possuíam maior impacto sobre a sua disponibilidade e confiabilidade. Utilizou-se o SI para medir a variação na disponibilidade em resposta a mudanças nos parâmetros de entrada, como o Tempo Médio de Carga da Bateria, Mean Time to Battery Charging (MTTBC) e o Tempo Médio de Descarga da Bateria, Mean Time to Battery Discharge (MTTBD). A análise de sensibilidade auxiliou na priorização de ações de melhoria, identificando quais componentes ou parâmetros deveriam ser otimizados.

zados para maximizar o impacto na disponibilidade do sistema, como o investimento em baterias de maior capacidade ou carregadores mais eficientes.

- **Análise de Resultados e Recomendações:** O modelo de performabilidade considerou a quantidade de rondas que o sistema era capaz de realizar levando em conta possíveis falhas e o tempo de substituição das baterias. A redundância de baterias foi um fator crítico para manter a disponibilidade do sistema de vigilância, permitindo que o drone continuasse suas operações sem grandes interrupções. Além disso, falhas potenciais do drone, como perda de sinal GPS ou falhas no motor, foram modeladas em um só tempo médio de falha para o drone inteiro, valor obtido na literatura e nas especificações do drone.

Esse modelo foi importante para avaliar a eficiência operacional do sistema e oferecer *insights* sobre o número ideal de baterias e drones necessários para garantir alta disponibilidade, performance e confiabilidade em um cenário de vigilância contínua. As recomendações incluíram intervenções práticas para melhorar a eficiência e a disponibilidade do sistema, tais como a adição de drones e baterias redundantes, a utilização de carregadores mais rápidos, ou o uso de baterias com maior capacidade de armazenamento. Também foram consideradas estratégias para balancear o custo-benefício, visando aumentar a disponibilidade do sistema sem elevar significativamente os custos operacionais.

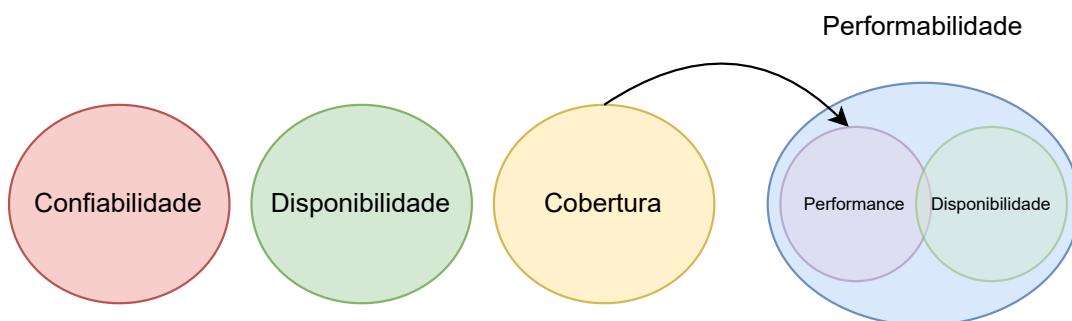
Essa metodologia permitiu a construção de um modelo de vigilância baseado em drones eficaz, considerando não apenas o desempenho operacional dos drones, mas também a necessidade de manter a vigilância contínua em cenários com falhas e trocas de baterias. O uso de ferramentas como Dashware, AirData e Bootstrap garantiu uma análise detalhada e precisa dos dados, permitindo a validação do modelo proposto e sua utilização em cenários futuros. Dessa forma, a metodologia proposta estabelece uma base para o desenvolvimento de sistemas VANT robustos, eficientes e adaptáveis, atendendo às demandas específicas de ambientes dinâmicos de vigilância.

4 ARQUITETURA E MODELOS

Este capítulo apresenta uma análise detalhada da arquitetura do sistema em estudo, com ênfase nos desafios associados ao monitoramento por VANTs. O objetivo é examinar os diversos aspectos críticos que influenciam a eficácia do monitoramento, identificando potenciais gargalos e propondo soluções que melhorem a eficiência operacional. Para isso, utilizamos diferentes metodologias que permitem uma avaliação de cada componente do sistema, considerando tanto os fatores internos quanto externos que afetam o desempenho. Propomos uma abordagem que integra modelos analíticos e numéricos para avaliar e otimizar o desempenho global do sistema, garantindo que cada uma das variáveis seja tratada de maneira sistemática, com foco na obtenção dos resultados mais eficazes.

Inicialmente, desenvolvemos um modelo estocástico fundamentado em CTMC, a partir do qual derivamos um modelo analítico para estimar diversos parâmetros temporais críticos, como tempos médios de transição entre estados e métricas de desempenho relacionadas ao comportamento estocástico do sistema. Posteriormente, elaboramos um modelo numérico utilizando SPN para analisar a disponibilidade do sistema, considerando diferentes configurações de redundância e suas implicações no comportamento do sistema (Fig. 10). Esse modelo foi subsequentemente estendido para incorporar estado absorvente, o que permitiu uma avaliação da confiabilidade do sistema, fornecendo uma visão sobre as possíveis falhas e a probabilidade de recuperação em diferentes cenários operacionais.

Figura 10 – Modelos de Avaliação Propostos para Sistemas de Monitoramento por VANTs e suas Inter-relações.

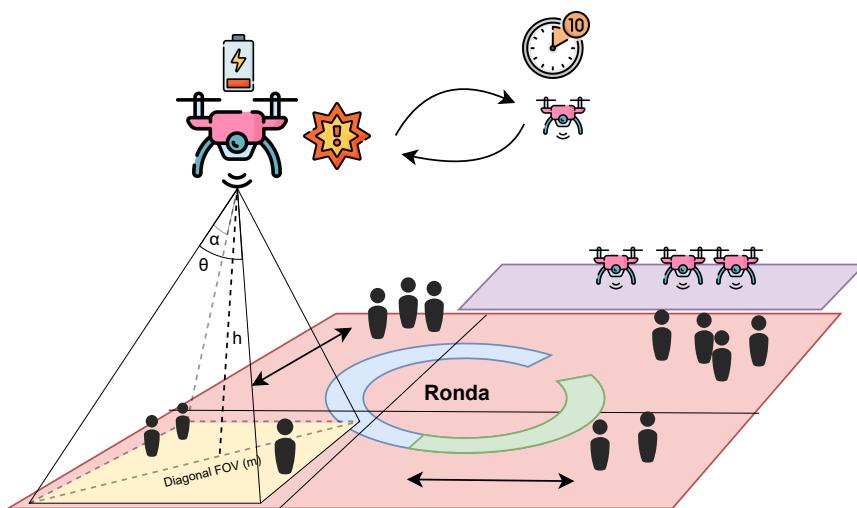


Fonte: Elaborado pelo Autor (2024)

No que se refere à cobertura de área, elaboramos um modelo que contempla as características do sensor da câmera, incluindo resolução, dimensões e campo de visão, Field of

View (FOV). Esse modelo contempla as especificações técnicas da câmera, incluindo resolução, dimensões e FOV. Esse modelo possibilita a estimativa da altura operacional máxima, o tempo efetivo de cobertura, bem como a análise do impacto de variações na resolução sobre a qualidade das imagens obtidas. Os resultados obtidos foram integrados em um modelo SPN de performabilidade, proporcionando uma análise detalhada do desempenho do sistema em diferentes condições operacionais, considerando cenário de falhas parciais, interrupções temporárias do serviço e diferentes níveis de redundância.

Figura 11 – Arquitetura de Vigilância por Drones Ilustrando o Campo de Visão e a Altura Operacional.



Fonte: Elaborado pelo Autor (2024)

A Figura 11 ilustra detalhadamente a arquitetura de vigilância por drones, destacando elementos cruciais para o entendimento do sistema de monitoramento. No centro superior da imagem, observamos o drone principal, equipado com uma câmera de alta resolução e uma bateria, simbolizando a unidade central de vigilância. A partir deste drone, projeta-se uma pirâmide de base retangular, que representa a área de cobertura da câmera (FOV), cujo ângulo é indicado por θ . Este ângulo é fundamental para determinar a área de cobertura do drone. A altura operacional, denotada por h , representa a distância vertical entre o drone e a superfície monitorada, sendo crucial para calcular a área de cobertura e a resolução efetiva das imagens capturadas.

No centro da imagem, uma elipse ilustra a área de ronda, representando a zona principal de vigilância onde o drone realiza seu patrulhamento. À direita, visualizamos um drone de substituição, indicando a estratégia de redundância implementada para manter a continuidade da operação. As setas circulares entre os drones sugerem o ciclo de operação, demonstrando a

rotação e substituição planejada para otimizar o tempo de voo e a eficiência energética. No solo, figuras humanas representam a escala e a capacidade do sistema em monitorar movimentações na área. Esta configuração permite calcular parâmetros essenciais como a largura total da área coberta pela câmera, que é determinada pela projeção do FOV no solo. A relação entre H e θ define diretamente esta área de cobertura, influenciando significativamente a eficácia do monitoramento.

Um dos principais desafios enfrentados neste estudo consiste na otimização do tempo de monitoramento de uma área entre dois pontos, considerando as restrições de eficiência energética e o desgaste dos dispositivos. A eficiência energética dos VANTs é um fator importante, especialmente em missões de reconhecimento de imagem, nas quais a resolução do sensor da câmera desempenha um papel determinante. Resoluções mais altas permitem reconhecer objetos a distâncias maiores, ampliando o campo de visão e reduzindo potencialmente o tempo necessário para a cobertura completa da área. Contudo, essa abordagem também aumenta a demanda energética, exigindo baterias mais robustas em termos de peso também e elevando o consumo de energia devido à maior potência requerida pelos rotores.

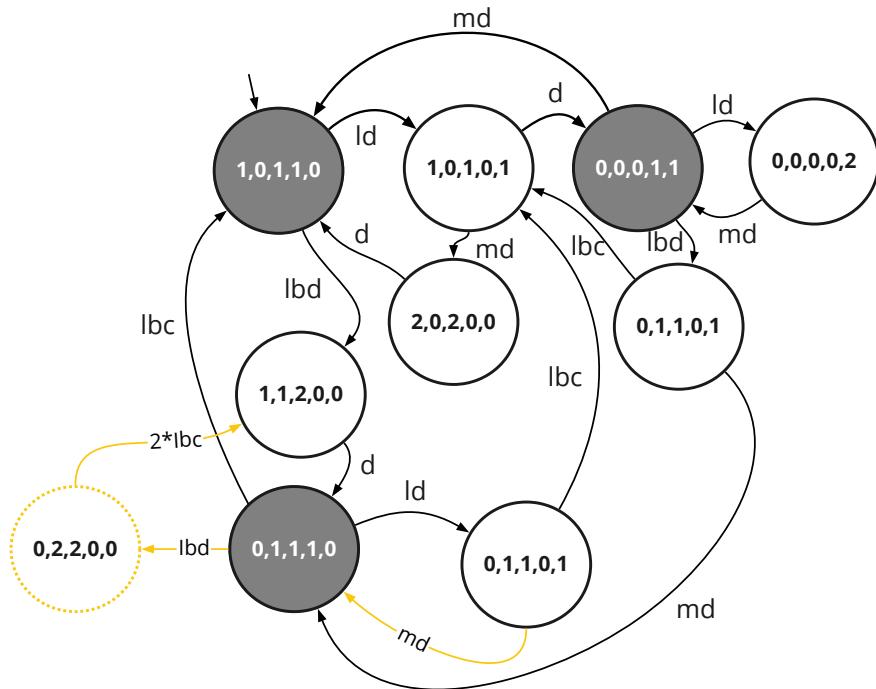
Para mitigar esses desafios, exploramos estratégias como a redundância de baterias, que envolve aceitar breves interrupções de serviço em prol de uma operação mais prolongada. Além disso, investigamos o uso de sensores de menor resolução associados ao posicionamento do VANT mais próximo do alvo. Embora essa estratégia limite o FOV, ela pode potencialmente aumentar o tempo de cobertura e melhorar a eficiência energética, ao mesmo tempo, em que reduz o desgaste dos dispositivos. No entanto, é imprescindível investigar este trade-off, pois o VANT cobre a área de forma mais lenta, necessitando de mais trocas de baterias, mas sem exigir que os rotores operem em potência máxima.

4.1 MODELO DE DISPONIBILIDADE

Esta seção apresenta um modelo de Cadeia de Markov de Tempo Contínuo (CTMC) e seu gráfico de alcançabilidade desenvolvidos para calcular a disponibilidade do sistema de voo do Veículo Aéreo Não Tripulado (VANT). Este modelo foi projetado para representar as diferentes configurações e estados operacionais do sistema, considerando fatores como o carregamento e descarregamento da bateria, falhas de hardware, reparos e a troca entre drones ativos e de reserva. A utilização de CTMC permite uma análise detalhada das transições entre estados e fornece uma base para a derivação de fórmulas analíticas que quantificam a

disponibilidade do sistema. As duas representações do modelo, embora equivalentes em termos de informação, oferecem perspectivas complementares que podem auxiliar na compreensão e análise do comportamento do sistema em diferentes cenários.

Figura 12 – Gráfico de Alcançabilidade para Disponibilidade de Sistemas de Vigilância por Drone



Fonte: Elaborado pelo Autor (2024)

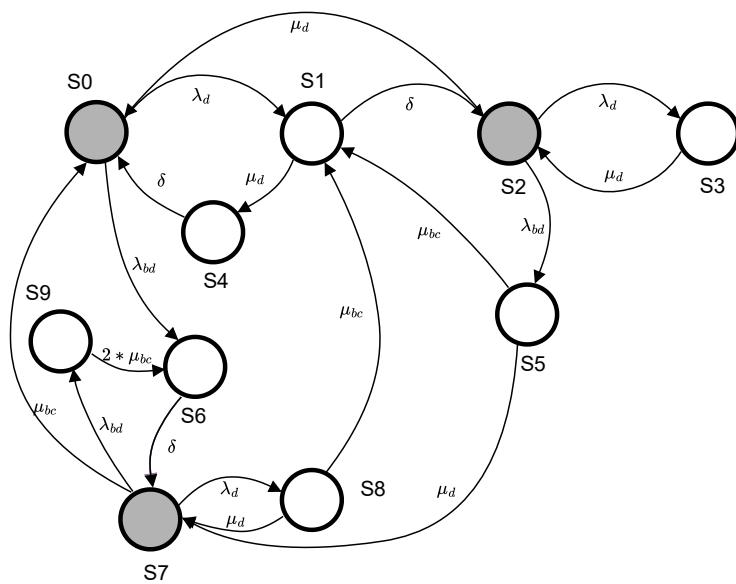
A Figura 12 apresenta uma cadeia de Markov que modela o sistema de voo do drone. O sistema é composto por um drone em voo com bateria, um drone reserva e uma bateria reserva em modo de operação em cold standby, o sistema é considerando em funcionamento quando um drone com bateria está ativo e em voo. A cadeia é composta por estados, representados por círculos, onde os círculos escuros indicam o sistema em operação normal. Os estados do sistema são descritos por cinco componentes: número de Baterias Prontas (**#BR**), número de Baterias Carregando (**#BC**), número de Drones Prontos (**#DR**), número de Drones em Operação (**#DU**) e número de Drones em Falha (**#DF**), representando a tupla $S=(\#BR, \#BC, \#DR, \#DU, \#DF)$. O estado inicial, representado como $S=(1,0,1,1,0)$, indica 1 bateria pronta, 0 baterias carregando, 1 drone pronto, 1 drone em operação e 0 drones em falha. Este estado inicial representa a configuração padrão do sistema quando está totalmente operacional e pronto para iniciar suas atividades.

As transições entre os estados são governadas por vários parâmetros: taxa de falha do drone (**Id**), taxa de reparo do drone (**md**), taxa de comutação (**d**), taxa de descarga da

bateria (**Ibd**) e taxa de carga da bateria (**Ibc**). Estas transições são representadas por setas entre os círculos, mostrando como o sistema pode mudar de um estado para outro. A dinâmica do sistema é caracterizada por movimentos entre diferentes estados, dependendo de eventos como falhas de drones, reparos, trocas de baterias e recargas. Por exemplo, o sistema pode passar de um estado operacional (círculos escuros) para um estado de falha através de eventos como falha de drone (**Id**) ou descarga de bateria (**Ibd**). Da mesma forma, pode retornar a estados operacionais por meio de reparos de drones (**md**) ou recarga de baterias (**Ibc**).

A partir do estado inicial $S=(1,0,1,1,0)$, o sistema pode evoluir para diferentes configurações, ilustrando a complexidade e dinamismo do modelo. Por exemplo, se o drone em operação falhar, o sistema pode transitar para o estado $S=(1,0,1,0,1)$, onde um drone está em falha e o outro está pronto para substituí-lo. Se a bateria em uso descarregar, representado pelos estados $S=(1,1,2,0,0)$ e $S=(0,1,1,0,1)$, o sistema pode mudar para $S=(0,1,1,1,0)$ a partir destes estados, iniciando o processo de recarga da bateria esgotada enquanto o drone continua operando com a bateria reserva. Estas transições demonstram como o sistema se adapta a diferentes situações, mantendo a operacionalidade sempre que possível e iniciando processos de recuperação quando necessário.

Figura 13 – Modelo de Disponibilidade CTMC para Sistemas de Vigilância por Drone



Fonte: Elaborado pelo Autor (2024)

A Figura 13 apresenta uma representação alternativa do mesmo modelo de CTMC para o sistema de voo do VANT, gerada pela ferramenta de cálculo Mercury (MACIEL et al., 2017).

Esta visualização mantém os mesmos parâmetros e estrutura do modelo original, incluindo a taxa de carregamento (μ_{bc}) e a taxa de descarregamento (λ_{bd}) da bateria do drone por hora, bem como a taxa de falha do hardware do dispositivo (λ_d) e a taxa de reparo (μ_d) por hora. Além disso, o modelo considera a taxa de troca (δ) entre o drone em voo e o drone de reserva. Nesta representação, os estados operacionais do sistema são claramente identificados como S_0, S_2, S_7 , indicados por círculos escuros. Estes estados representam as configurações onde o sistema está em pleno funcionamento, com pelo menos um drone ativo e em voo. A visualização gerada pelo ferramenta oferece uma perspectiva complementar do modelo CTMC, permitindo uma análise mais aprofundada das transições entre estados e das probabilidades associadas a cada configuração do sistema. Uma descrição detalhada de todos os parâmetros e estados das duas CTMCs pode ser vista no Quadro 2 e 3, fornecendo uma referência completa para a compreensão e análise do modelo.

O modelo CTMC apresentado serve como base para a obtenção de um modelo analítico. Esta abordagem fornece uma estrutura que arquitetos e projetistas podem utilizar no desenvolvimento de sistemas com características similares, permitindo a análise do comportamento e da confiabilidade do sistema de voo do VANT. Uma característica deste modelo é o uso de tempos distribuídos exponencialmente, possibilitando a derivação de uma fórmula em forma fechada para a disponibilidade do sistema. Esta fórmula, representada pela Eq. 4.1, oferece uma expressão matemática calculável para a avaliação do desempenho do sistema em diferentes cenários operacionais.

Após a apresentação dos modelos CTMCs para o cálculo da disponibilidade do sistema de voo do VANT, passamos às equações analíticas derivadas desses modelos. Estas equações fornecem uma representação matemática da disponibilidade do sistema, permitindo uma análise quantitativa do seu desempenho em diferentes cenários operacionais.

A seguir, apresentamos a fórmula em forma fechada para a disponibilidade do VANT extraídas a partir do modelo CTMC (Modelo 13) com auxílio da ferramenta Wolfram Mathematica (WOLFRAM, 2024). Além disto, a equação da disponibilidade do VANT é seguida pelas equações que descrevem a disponibilidade do servidor e do roteador. Incluímos os outros componentes para uma visão abrangente do sistema de monitoramento, embora o foco principal seja o sistema de voo do VANT. Por fim, apresentamos a equação que combina esses elementos para calcular a disponibilidade geral do sistema.

Quadro 2 – Descrição dos Estados do Sistema para o Modelo CTMC

Estado	Ferramenta	Sistema	Descrição
(1,0,1,1,0)	S_0	Operacional	Uma bateria pronta, nenhuma bateria carregando, um drone pronto, um drone em uso, nenhum drone em falha
(1,0,1,0,1)	S_1	Indisponível	Uma bateria pronta, nenhuma bateria carregando, um drone pronto, nenhum drone em uso, um drone em falha
(0,0,0,1,1)	S_2	Operacional	Nenhuma bateria pronta disponível, nenhuma bateria carregando, nenhum drone pronto, um drone em uso, um drone em falha
(0,0,0,0,2)	S_3	Indisponível	Nenhuma bateria pronta disponível, nenhuma bateria carregando, nenhum drone pronto, nenhum drone em uso, dois drones em falha
(1,1,2,0,0)	S_6	Indisponível	Uma bateria pronta, uma bateria carregando, dois drones prontos, nenhum drone em uso, nenhum drone em falha
(2,0,2,0,0)	S_4	Indisponível	Duas baterias prontas, nenhuma bateria carregando, dois drones prontos, nenhum drone em uso, nenhum drone em falha
(0,1,1,0,1)	S_5	Indisponível	Nenhuma bateria pronta, uma bateria carregando, um drone pronto, nenhum drone em uso, um drone em falha
(0,2,2,0,0)	S_9	Indisponível	Nenhuma bateria pronta, duas baterias carregando, dois drones prontos, nenhum drone em uso, nenhum drone em falha
(0,1,1,1,0)	S_7	Operacional	Nenhuma bateria pronta, uma bateria carregando, um drone pronto, um drone em uso, nenhum drone em falha
(0,1,1,0,1)	S_8	Indisponível	Nenhuma bateria pronta, uma bateria carregando, um drone pronto, nenhum drone em uso, um drone em falha

Fonte: Elaborado pelo Autor (2024)

Quadro 3 – Descrição dos Parâmetros para o Modelo CTMC

Parâmetro	Ferramenta	Descrição
l_{bd}	λ_{bd}	Taxa de descarga da bateria por hora
l_{bc}	λ_{bc}	Taxa de carga da bateria por hora
m_d	μ_d	Taxa de reparo de drones por hora
l_d	λ_d	Taxa de falhas de drones por hora
d	δ	Taxa de comutação de drones por hora

Fonte: Elaborado pelo Autor (2024)

$$A_{VANT} = \frac{\delta \lambda_{bc} \mu_d (\alpha_2 \delta \phi_2 + \beta_2 \mu_d \phi_1)}{\alpha_2 \delta^2 \theta_2 + \lambda_{bc} \mu_d (\alpha_3 \delta \lambda_{bc} \lambda_{bd} \lambda_d + \theta_1 \mu_d) + \beta_2 \mu_d^3 \phi_3} \quad (4.1)$$

Onde:

$$\beta = \lambda_{bd} + \lambda_d;$$

$$\beta_2 = \lambda_{bd} + \mu_d;$$

$$\beta_3 = \lambda_d + \mu_d;$$

$$\beta_4 = \lambda_{bc} + \lambda_{bd};$$

$$\beta_5 = \lambda_{bc} + \mu_d;$$

$$\alpha_1 = \beta + \lambda_{bc};$$

$$\alpha_2 = \beta + \beta_5;$$

$$\alpha_3 = \beta_3 + \beta_4;$$

$$\alpha_4 = \beta_3 \lambda_{bc} + \lambda_{bd} \mu_d;$$

$$\phi_1 = \alpha_1 \lambda_{bc} + \beta_4 \mu_d;$$

$$\phi_2 = \beta_3 \lambda_{bc} + \lambda_{bd} \mu_d;$$

$$\phi_3 = \beta \lambda_{bc}^2 + \lambda_{bd} (\lambda_{bd} (\delta + \lambda_{bc}) + 2 \delta \lambda_{bc});$$

$$\phi_4 = \beta_3^2 + \beta_3 (\lambda_{bc} + 3 \lambda_{bd}) + \lambda_{bd} (2 \lambda_{bc} + 3 \lambda_{bd});$$

$$\phi_5 = \lambda_d^2 + \lambda_d \mu_d + \mu_d^2;$$

$$\theta_1 = \alpha_1 \beta \beta_2 \lambda_{bc} + 2 \beta \beta_2 \delta \lambda_{bd} + \delta \lambda_{bc} \phi_4;$$

$$\theta_2 = \alpha_4 \lambda_{bd} \mu_d + \lambda_{bc}^2 \phi_5;$$

As equações 4.2 e 4.3 apresentam as fórmulas analíticas para a disponibilidade do servidor e do roteador, respectivamente. Embora não sejam incluídos nas análises de sensibilidade ou na avaliação da disponibilidade do sistema, esses componentes são apresentados para completude. O foco da análise de melhoria de disponibilidade é o dispositivo VANT, considerado o principal gargalo do sistema.

$$A_{Server} = \frac{\lambda_{hw}}{\lambda_{hw} + \mu_{hw}} \times \frac{\lambda_{os}}{\lambda_{os} + \mu_{os}} \times \frac{\lambda_{hp}}{\lambda_{hp} + \mu_{hp}} \times \frac{\mu_{vm}}{\lambda_{vm} + \mu_{vm}} \quad (4.2)$$

$$A_R = \frac{\lambda}{\lambda + \mu} \quad (4.3)$$

Os modelos analíticos para a disponibilidade do servidor (Eq. 4.2) e do roteador (Eq. 4.3) incorporam a taxa de falha (λ) e a taxa de reparo (μ). O modelo do servidor inclui componentes

típicos de um sistema de monitoramento: hardware (*hw*), sistema operacional (*os*), *hipervisor* de gerenciamento de máquina virtual (*hp*) e máquina virtual (*vm*).

A disponibilidade geral do sistema é dada pela Eq. 4.4:

$$A = A_{Server} \times A_R \times A_{VANT} \quad (4.4)$$

Esta equação representa o produto dos modelos de disponibilidade do servidor, roteador e sistema de voo do VANT.

As equações apresentadas nesta seção estabelecem a base matemática para a análise da disponibilidade do sistema de monitoramento baseado em VANT. Elas representam as interações entre os diferentes componentes e estados operacionais, possibilitando uma avaliação quantitativa do desempenho do sistema. A obtenção de fórmulas em forma fechada para o cálculo analítico é particularmente relevante, ao permitir a realização de análises sem a necessidade de ferramentas computacionais específicas. Isso facilita a execução de análises de sensibilidade e estudos comparativos, auxiliando na identificação de fatores que influenciam a disponibilidade do sistema e na avaliação de estratégias para sua melhoria. A compreensão dessas equações contribui para a interpretação dos resultados das análises e para orientar decisões de projeto e operação do sistema de monitoramento.

4.1.1 Modelo de Redundância SPN

O modelo analítico de disponibilidade do sistema de voo do VANT, conforme apresentado na Eq. 4.1, é formulado para avaliar a disponibilidade de um modo básico de operação do sistema, que inclui um VANT em voo, um VANT de reserva e uma bateria de reserva. Além disso, para aumentar a métrica de disponibilidade, pode-se variar os tempos de falha e reparo do VANT, da bateria e dos componentes de recarga. No entanto, a incorporação de mecanismos de redundância no modelo para um modo de operação mais avançado resultaria em um espaço de estados muito grande para a geração explícita de cadeias de Markov e para a obtenção de um modelo analítico. Para abordar essa questão, propomos um modelo de método numérico de SPN, que pode ser avaliado usando ferramentas computacionais como o Mercury (MACIEL et al., 2017).

Aplicar redundância a um sistema de vigilância por drones o torna mais resiliente a falhas, aumentando sua disponibilidade. Alguns modelos, como cadeias de Markov de tempo

contínuo, podem modelar um certo grau de redundância e calcular sua disponibilidade e confiabilidade. No entanto, à medida que aumentamos o número de dependências e componentes sobressalentes, o espaço de estados de uma CTMC cresce substancialmente, tornando sua manutenção inviável. Para resolver este problema, propomos usar modelos numéricos de SPN para disponibilidade e confiabilidade, que podem ser construídos e avaliados com a ajuda de ferramentas computacionais como Mercury (MACIEL et al., 2017).

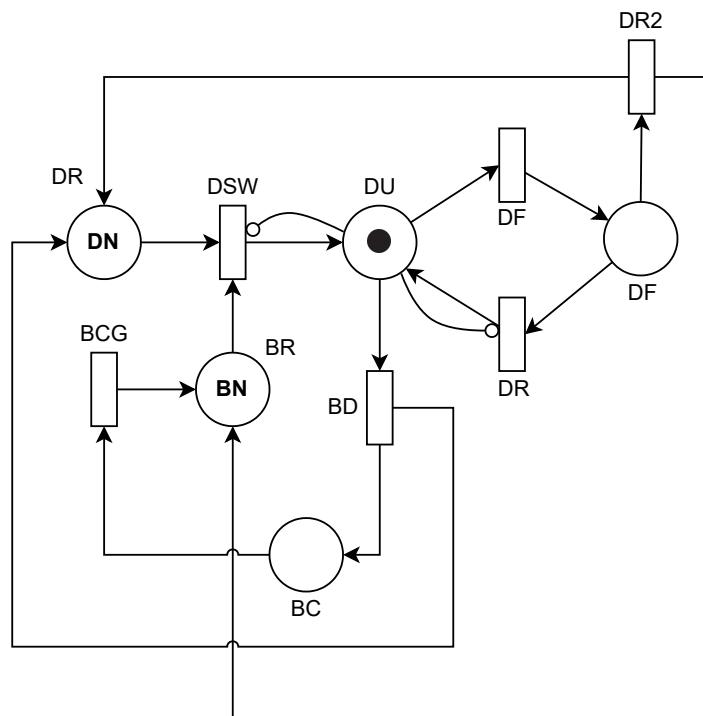
O modelo de disponibilidade suporta uma análise abrangente da disponibilidade do sistema. Este modelo permite a estimativa da disponibilidade instantânea e em estado estacionário e métricas essenciais como tempo de inatividade, tempo de atividade e parâmetros relacionados. Por outro lado, um modelo de confiabilidade (Figura 15) é fundamental no cálculo de métricas como tempo médio até a falha, tempo mediano até a falha, percentis e não confiabilidade. Este modelo pode ser representado por redes de Petri estocásticas com uma marcação absorvente.

A Figura 14 ilustra um modelo de disponibilidade SPN usado para representar a implementação de mecanismos de redundância no sistema de vigilância e para calcular a disponibilidade. Este modelo é composto por cinco lugares, **DR**, **DU**, **DF**, **BR** e **BC**; seis transições temporizadas exponenciais, **DSW**, **DF**, **DR2**, **BCG**, **BD** e **DRR**; e seus arcos. A Tabela 4 representa os atributos das transições. Todas as transições são marcadas independentemente, e sua semântica de servidor é SSS. Todas as transições têm prioridade um.

Um token no lugar **DU** representa o sistema como operacional. Isso significa que um drone equipado com bateria está ativo e monitorando a área-alvo. Por outro lado, a presença de um token no lugar **DF** indica uma falha do sistema resultante de um defeito no drone. Um token no lugar **BC** representa uma falha do sistema devido ao esgotamento da bateria do drone. No entanto, um token no lugar **BC** também indica que a bateria descarregada está agora sendo recarregada. Além disso, as quantidades de drones e baterias sobressalentes são representadas pelo número de tokens nos lugares **DR** e **BR**, respectivamente, conforme definido por **DN** e **BN**.

Neste modelo, dois arcos inibidores entre as transições **DSW** e **DR** e o lugar **DU** garantem que apenas um VANT possa estar ativo por vez e determinam se um VANT sobressalente ou recuperado pode assumir a posição se atender às condições necessárias. Dado o atraso atribuído, as transições **DRR** e **DR2** são disparadas assim que o reparo do drone é concluído. Transições temporizadas, representadas por retângulos brancos, dependem do atraso para serem habilitadas. Em contraste, transições imediatas, identificadas por retângulos pretos, são habilitadas assim que os tokens necessários estão presentes no lugar conectado (MELO et al.,

Figura 14 – Modelo de Disponibilidade Usando SPN para Sistemas de Vigilância por Drone



Fonte: Elaborado pelo Autor (2024)

2021)

Em operação mínima, o modelo opera sem drones e baterias sobressalentes, com zero tokens nos lugares **DR** e **BR**, ou seja, $DN = 0$ e $BN = 0$, enquanto um VANT com bateria está ativo com um token no lugar **DU**. O VANT tem tempos específicos como Tempo Médio até a Falha do Drone (**Mean Time to Drone Failure (MTTDF)**), Tempo Médio para Reparo do Drone (**Mean Time to Drone Repair (MTTDR)**) e Tempo Médio para Substituição do Drone (**Mean Time to Drone Swap (MTTDS)**), Tempo Médio para Carga (**MTTBC**) e Descarga da Bateria (**MTTBD**), todos representados por distribuições exponenciais. O Quadro 4 resume as transições, o tempo utilizado, as prioridades e as expressões de guarda utilizadas nas transições.

A disponibilidade do sistema de voo do VANT usando o método numérico pode ser obtida com a Eq. 4.5 usando uma notação semelhante ao Mercury.

$$A_{VANT} = P\{\#DU > 0\} \quad (4.5)$$

Quadro 4 – Parâmetros Associados a Transições dos Modelos de Disponibilidade e Confiabilidade SPN

Transição	Parâmetro	Prioridade	Expressão de Guarda	Descrição
DF	MTTDF	1		Transição exponencial com tempo médio para falha do drone
DR	MTTDR	1		Transição exponencial com tempo médio para reparo do drone
DR2	MTTDR	1	#DU > 0	Transição exponencial com tempo médio para reparo do drone
BD	MTTBD	1		Transição exponencial com tempo médio para descarga da bateria
BCG	MTTBC	1	#SF = 0	Transição exponencial com tempo médio para carregar a bateria
DSW	MTTDS	1	#SF = 0	Transição exponencial com tempo médio para troca de drones
TE0	TTSF	1		Transição exponencial com o tempo até a falha geral do sistema
TI0	*	2	#DU > 0	Transição imediata
TI1	*	1		Transição imediata
TI2	*	1	(#DU > 0) AND (#P4 > 0)	Transição imediata
TI3	*	1	(#DU > 0) AND (#P5 > 0)	Transição imediata
TI4	*	1		Transição imediata
TI5	*	2		Transição imediata
TI6	*	1		Transição imediata

Fonte: Elaborado pelo Autor (2024)

onde P calcula a probabilidade de que o sistema contenha tokens no estado ativo **DU**. A partir desta SPN, seu gráfico de alcançabilidade é gerado, e a respectiva CTMC é automaticamente obtida e resolvida usando métodos numéricos (MACIEL et al., 2017).

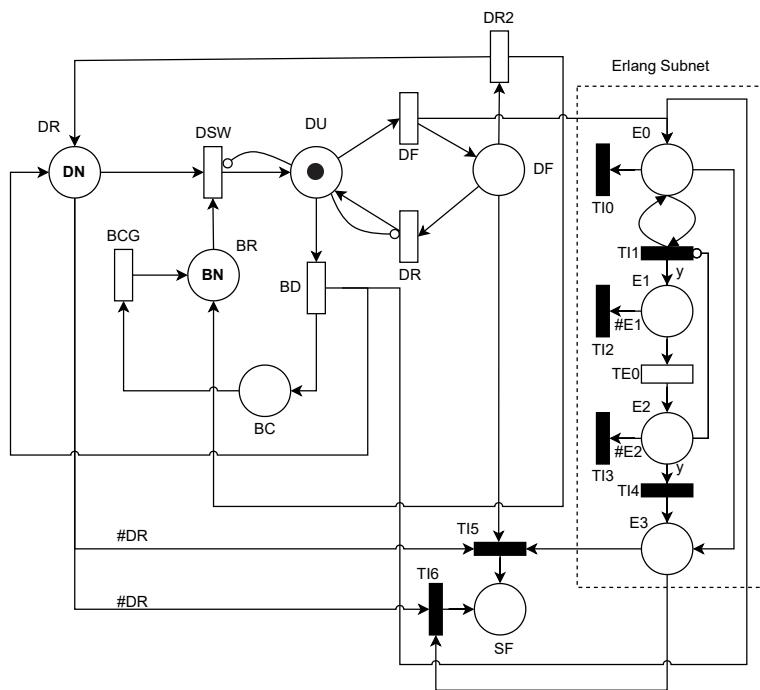
4.2 MODELO DE CONFIABILIDADE

Na vigilância por drones, a métrica de confiabilidade nos permite avaliar a probabilidade de que os drones realizem suas funções de vigilância sem falhas durante um determinado período ou sob condições específicas. Isso é crucial para garantir a eficácia contínua do sistema de vigilância, pois falhas nos drones podem resultar em lacunas na cobertura, perda de informações críticas e segurança comprometida.

Propusemos um modelo SPN para avaliar a confiabilidade do nosso sistema, como ilustrado na Figura 15. Este modelo é composto por cinco lugares e seis transições temporizadas, semelhante ao modelo de disponibilidade, preservando as mesmas propriedades. Além disso, incorpora os lugares **E0**, **E3** e de falha do sistema (**System Failure (SF)**), bem como três

transições imediatas (**TI0**, **TI5** e **TI6**) e seus respectivos arcos. Adicionalmente, o modelo também possui uma subrede do tipo Erlang, composta pelos lugares **E1** e **E2**, quatro transições imediatas (**TI1**, **TI2**, **TI3** e **TI4**) e uma transição temporizada exponencial **TE0**. Todas as transições têm prioridade um; sua semântica de servidor é SSS. No entanto, as transiões **TI5** e **TI0** têm prioridade sobre as outras, sendo atribuída uma prioridade de dois.

Figura 15 – Modelo de Confiabilidade Usando SPN para Sistemas de Vigilância por Drone



Fonte: Elaborado pelo Autor (2024)

Além disso, o modelo também apresenta uma marcação absorvente $M=(\mathbf{DR}, \mathbf{DU}, \mathbf{DF}, \mathbf{BR}, \mathbf{BC}, \mathbf{E0}, \mathbf{E1}, \mathbf{E2}, \mathbf{E3}, \mathbf{SF})=(0, 0, 0, 0, 0, 0, 0, 0, 0, 1)$, simbolizando a falha do sistema após um período específico. Em certos contextos, a ausência de serviços é considerada uma falha apenas após um certo atraso. Assim, nosso modelo usa uma distribuição poliexponencial do tipo Erlang, com o objetivo de aproximar um tempo de descarga da bateria com distribuição determinística. Essa abordagem oferece uma representação mais direta da confiabilidade do sistema, equilibrando a necessidade de um limite de tempo fixo com a precisão da distribuição poliexponencial.

A subrede representa a distribuição Erlang do tipo $Erl(\gamma = y, \lambda = 1/\beta)$. Onde γ denota o parâmetro de forma, também conhecido como número de fases, λ representa o parâmetro de escala, correspondendo à taxa de cada fase exponencial. As redes de Petri comumente

representam este último valor como o atraso médio de cada fase. O Tempo até a Falha do Sistema, Time to System Failure (TTSF) é de três minutos e segue uma distribuição Erlang de dez fases e coeficiente de variação de 0,31 ($y = 10$, $cv = \frac{1}{\sqrt{y}} = 0,31$), a taxa de cada fase é definida por $1/\beta$, onde $\beta = TTSF/y$. À medida que aumentamos o número de fases, a precisão na representação de uma distribuição determinística melhora. Escolhemos uma configuração de distribuição Erlang de 10 fases para este estudo (número de fases é atribuído pelo valor do peso y , no arco que vai de **TI1** para **E1**). A escolha de tal valor visa equilibrar precisão e complexidade numérica.

Em nosso modelo, um token no lugar **E0** representa inatividade do serviço, seja devido à falha do drone (transição **DF**) ou descarga da bateria (transição **BD**). Este token permite que a transição **TI1** dispare, armazenando um número y de tokens no lugar **E1**; os tokens são consumidos de acordo com o atraso atribuído à transição **TE0**, ela dispara assim que este tempo é atingido, armazenando tokens no lugar **E2**. A transição **TI4** é habilitada e disparada assim que um número de tokens y é encontrado em **E2**, armazenando um token no lugar **E3**. Um token no lugar **E3** habilita a transição **TI5** se o drone falhar ou a transição **TI6** se o drone descarregar, removendo **#DR** tokens do lugar **DR** e um token do lugar **DF**.

Uma vez disparadas, as transições **TI5** e **TI6** armazenam um token no lugar **SF** alcançando a marcação M (estado absorvente), que representa uma falha do sistema devido a um tempo prolongado de inatividade do serviço. No entanto, esse processo de falha pode ser interrompido se o sistema for reativado, seja pela manutenção do drone (transição **DR**) ou pela substituição por um novo drone e bateria (transição **DSW**). As transições imediatas **TI0**, **TI2** e **TI3** permitem essa quebra de tempo no modelo de distribuição Erlang, removendo todos os tokens dos lugares **E0**, **E1** e **E2** assim que as condições de guarda são quebradas (conforme descrito na Quadro 4).

4.3 MODELO DE COBERTURA

O modelo de cobertura é um componente importante para o planejamento de missões de vigilância com drones. Este modelo considera diversos fatores, incluindo as características da câmera do drone, a área a ser monitorada e os requisitos de resolução para identificação de objetos-alvo. Nesta seção, apresentaremos os cálculos e considerações necessários para desenvolver um modelo de cobertura que atenda as especificações da missão. O Quadro 5 apresenta uma descrição detalhada dos parâmetros utilizados no modelo de cobertura, fornecendo uma

visão geral dos elementos que serão discutidos ao longo desta seção.

Quadro 5 – Parâmetros Modelo de Tempo de Cobertura

Parâmetro	Descrição
FL	Distância focal do sensor da câmera em mm
$CS_i\{CS_h, CS_w\}$	Altura do sensor da câmera em mm Largura do sensor da câmera em mm
$FV_{\theta i}\{FV_{\theta h}, FV_{\theta w}\}$	Ângulo vertical do campo de visão Ângulo horizontal do campo de visão
R_h	Resolução vertical do sensor da câmera em pixels
O_{real}	Altura do objeto real observado em metros
O_{img}	Altura do objeto observado na imagem capturada em pixels
H_{max}	Altura máxima da câmera ao objeto observado dada a altura desejada na imagem capturada em metros
$FV_i\{FV_h, FV_w\}$	Altura do campo de visão em metros Largura do campo de visão em metros
$A_i\{A_l, A_w\}$	Comprimento da área em metros Largura da área em metros
$N_i\{N_{ln}, N_{col}\}$	Número de linhas verticais dado A_h e FV_h Número de colunas horizontais dado A_w e FV_w
D_{speed}	Velocidade do VANT em m/s
CoV_{len}	Distância percorrida pelo VANT em metros para cobrir toda a área
CoV_{time}	Tempo gasto pelo VANT para cobrir toda a área em minutos, dado CoV_{len} e D_{speed}

Fonte: Elaborado pelo Autor (2024)

Inicialmente, abordaremos o cálculo do ângulo de visão da câmera, que é relevante para determinar a área que pode ser capturada em uma única imagem. Em seguida, discutiremos como a distância entre o drone e o objeto observado afeta a qualidade da imagem e a capacidade de reconhecimento. Apresentaremos fórmulas para calcular a distância máxima que o drone pode alcançar, mantendo a resolução desejada do objeto-alvo. Além disso, exploraremos como dividir a área de interesse em segmentos menores, permitindo uma cobertura sistemática. Analisaremos as diferenças entre áreas regulares e irregulares. Por fim, apresentaremos equações para calcular a distância total percorrida pelo drone e o tempo necessário para cobrir a área de interesse. Estas considerações são fundamentais para otimizar o uso do drone em missões de vigilância, garantindo uma cobertura eficiente e eficaz da área alvo.

O modelo de cobertura proposto foi validado através de experimentos práticos, utilizando um drone comercial em um cenário de vigilância simulado num ambiente real. Esta validação é

necessária para garantir que o modelo seja aplicável e preciso em condições reais, considerando variáveis como velocidade do drone e duração da bateria. A validação experimental permitirá ajustar e refinar o modelo, assegurando sua relevância prática e confiabilidade em diferentes cenários de vigilância. Esta seção fornecerá uma base para compreender como otimizar missões de vigilância com drones, equilibrando a qualidade da cobertura com a eficiência operacional.

O ângulo de visão da câmera (FOV), medido em graus, é determinado pela distância focal do sensor até a lente e pela dimensão horizontal ou vertical do mesmo, dependendo do ângulo desejado.

$$FV_{\theta i}(FL, CS_i) = 2 \times \arctan\left(\frac{CS_i}{FL}\right) \times \frac{180}{\pi}. \quad (4.6)$$

Para calcular o ângulo do triângulo completo, usamos a função arco tangente da razão entre CS_i e FL para determinar o ângulo do triângulo retângulo e, em seguida, dobramos esse valor (NGO; ABDUKHAKIMOV; KIM, 2019).

Aumentar a distância entre a câmera do VANT e o objeto observado expande o campo de visão. No entanto, isso pode diminuir a densidade de pixels por unidade de área, fazendo com que o objeto pareça menor e menos definido na imagem, tornando o reconhecimento mais desafiador. Para resolver esse dilema, calculamos a distância máxima que o drone poderia alcançar, considerando a altura desejada do objeto na imagem como um parâmetro. Como mostrado na Equação 4.7.

$$H_{max}(O_{real}, O_{img}, R_h, FV_{\theta i}) = \frac{O_{real} \times R_h}{2 \times \tan\left(\frac{FV_{\theta i} \times \frac{\pi}{180}}{2}\right) \times O_{img}}. \quad (4.7)$$

A altura real do objeto sob observação é indicada como O_{real} , enquanto O_{img} representa a altura do objeto na imagem capturada. R_h refere-se à resolução vertical do sensor da câmera, e $FV_{\theta i}$ representa o ângulo horizontal ou vertical que define o campo de visão em graus.

A altura vertical do objeto, em conjunto com a resolução vertical, é frequentemente um exemplo relevante em sistemas de monitoramento de pessoas, dado que a altura é geralmente a dimensão predominante neste contexto. No entanto, é essencial destacar que se o objeto for mais largo do que sua altura, é aconselhável considerar a largura e a resolução horizontal como parâmetros de análise.

$$FV_i(H_{max}, FV_{\theta i}) = H_{max} \times \tan\left(\frac{\frac{FV_{\theta i}}{2} \times \pi}{180}\right) \times 2. \quad (4.8)$$

Com base nos ângulos de abertura horizontal e vertical e na altura máxima permitida, calculamos as dimensões horizontais e verticais reais do campo de visão da câmera (FV_i) em metros. A partir desses cálculos, torna-se viável subdividir a área de interesse em segmentos menores, que o drone pode capturar em momentos específicos, dividindo a área de monitoramento em várias linhas e colunas (N_i).

$$N_i = \frac{A_i}{FV_i}. \quad (4.9)$$

Considerando a área que a câmera pode capturar, determinada pelas dimensões horizontais e verticais do FOV, e considerando a influência da altitude, o drone em operação percorrerá uma distância um pouco menor do que a necessária para cobrir completamente a área de interesse. Isso acontece porque o ângulo de visão da câmera no VANT é maior do que as dimensões físicas do próprio VANT.

A Equação 4.10 calcula a distância percorrida pelo drone, considerando a diferença entre a distância coberta pelo drone e a extensão total da área de interesse.

$$CoV_{len}(N_{ln}, N_{col}, FV_h, FV_w) = N_{ln} \times ((N_{col} - 1) \times FV_w) + (N_{ln} - 1) \times FV_h, \quad (4.10)$$

onde N_{ln} e N_{col} denotam o número de linhas e colunas resultantes da divisão da área de interesse na área de captura do drone. Estas linhas e colunas são então multiplicadas na fórmula pelos parâmetros FV_h e FV_w , onde FV_h representa o comprimento vertical, e FV_w o comprimento horizontal do campo de visão do drone. Isso nos permite calcular a distância percorrida em metros (CoV_{len}).

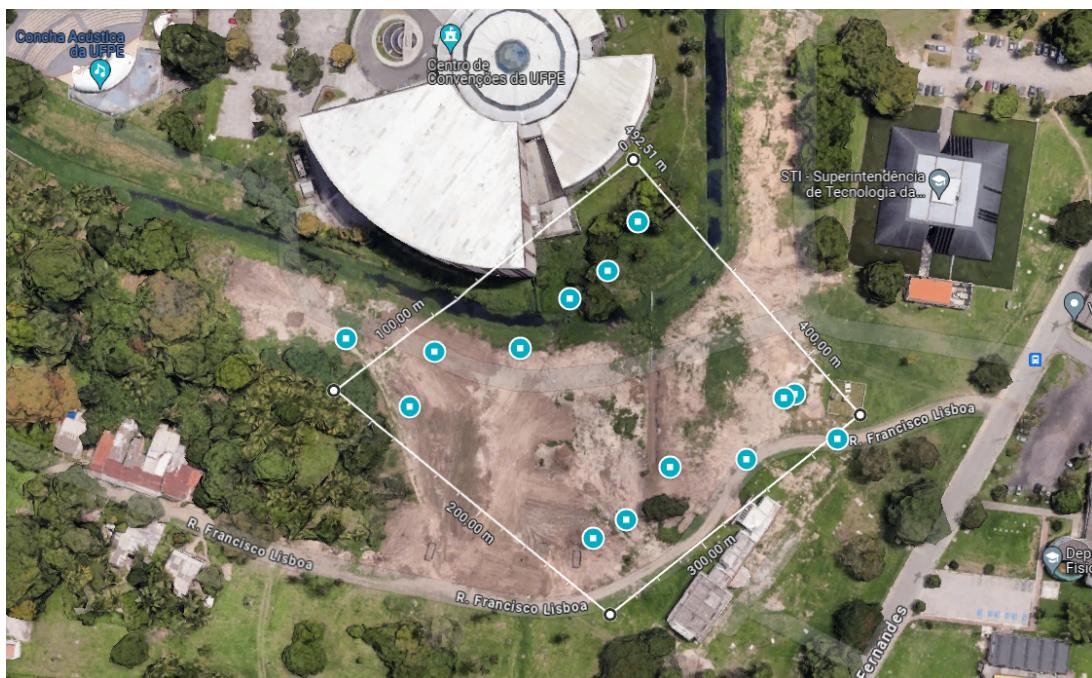
$$CoV_{time}(D_{speed}) = \frac{CoV_{len}}{D_{speed}}. \quad (4.11)$$

Usando a distância percorrida e a velocidade do drone (D_{speed}), a Equação 4.11 calcula o tempo necessário para cobrir completamente uma área de interesse em uma única passagem. No entanto, é essencial notar que esse tempo pode ser influenciado por várias variáveis, algumas das quais estão relacionadas ao sistema integrado de monitoramento aéreo no drone. Em contraste, outras são externas e além do nosso controle, como a força do vento na região, a umidade ou a pressão atmosférica.

4.3.1 Validação do Modelo de Cobertura

Nosso objetivo é fornecer um modelo que represente de perto um sistema do mundo real. Uma vez criado, é essencial validar este modelo para garantir sua adaptação ao cenário real. Como ponto de partida principal, consideramos um ambiente de monitoramento de vigilância com um drone equipado com uma bateria principal e três baterias sobressalentes para substituição. Cada bateria tinha uma certa porcentagem de carga, permitindo um número específico de voltas, considerando o início e o fim da área-alvo. Em seguida, definimos o tempo necessário para completar essas voltas com base em dados métricos exportados pelo drone utilizado (Tabela 1).

Figura 16 – Área de Vigilância Alvo Demonstrando Cobertura de Drones.



Fonte: Elaborado pelo Autor (2024)

Em nosso experimento, utilizamos um drone comercial DJI Mavic Pro equipado com um sensor de câmera semicondutor de óxido metálico complementar, Complementary Metal-Oxide-Semiconductor (CMOS) de 1/2.3" com 12,35 megapixels, uma distância focal efetiva de 4,89 mm e dimensões de 3,816 mm por 6,780 mm. A resolução de vídeo escolhida para gravação foi Full HD (1920×1080). O objeto-alvo era uma pessoa com altura média de 1,70 metros, e a área de cobertura média era de 125 m por 122 m (Fig. 16). O objeto-alvo tinha uma resolução vertical de 31 pixels na imagem capturada, permitindo melhor visualização e reconhecimento durante a missão de vigilância. Obtivemos dados de coordenadas geográficas, tempo e veloci-

dade através dos dados capturados pelo drone extraídos usando o serviço Airdata (AIRDATA, 2024) (Fig. 17).

Figura 17 – Métricas Sobrepostas na Imagem Capturada pelo Drone durante o Monitoramento.



Fonte: Elaborado pelo Autor (2024)

Tabela 1 – Especificações do Teste de Validação

Execução	1	2	3	4	5	6	7	8	9	10	11	12
Tempo(s)	183	133	183	177	186	185	164	185	168	188	164	180

Fonte: Elaborada pelo autor (2024)

Para melhor visualização, utilizamos a ferramenta Dashware para plotar medidores sobrepostos e avaliamos os tempos médios (Tabela 1)(DASHWARE, 2024). O experimento durou em média 2096 segundos com quatro baterias, considerando os níveis de carga de cada bateria. A partir das informações coletadas, calculamos o intervalo de confiança usando o método *bootstrap* para o tempo médio de cobertura da área-alvo uma vez. Foi aplicado um intervalo de confiança de 95%.

Concluímos que o tempo médio está entre $165,16667 < X < 181,95833$ segundos. Calculamos o tempo médio para cobrir a área-alvo com o modelo de cobertura proposto neste trabalho (expresso nas Equações 4.10 e 4.11) e obtivemos um tempo médio de 173,56541 segundos, que está dentro do intervalo de confiança. Portanto, não temos evidências para rejeitar o modelo proposto, confirmando sua adequação ao sistema do mundo real.

4.4 MODELO DE PERFORMABILIDADE

O modelo de performabilidade proposto nesta seção visa avaliar o desempenho e a confiabilidade de sistemas de vigilância por drones, integrando aspectos de performance e disponibilidade. Este modelo considera o tempo necessário para um drone completar uma varredura completa de uma área específica, abrangendo desde o início da missão até sua conclusão, incluindo a viagem de ida para a área de interesse e o retorno à base. Além disso, o modelo analisa como a disponibilidade do sistema afeta o tempo de varredura e examina o impacto da implementação de redundância no aumento do tempo de monitoramento efetivo.

Dada a complexidade envolvida na modelagem e a necessidade de flexibilidade na parametrização, optou-se por um modelo numérico baseado em SPN. Esta abordagem permite uma representação detalhada dos diversos estados e transições do sistema, facilitando a análise de cenários complexos e a avaliação de diferentes configurações de redundância. O modelo pode ser avaliado usando ferramentas computacionais especializadas, como o software Mercury (MACIEL et al., 2017), que oferece recursos avançados para simulação e análise de SPNs.

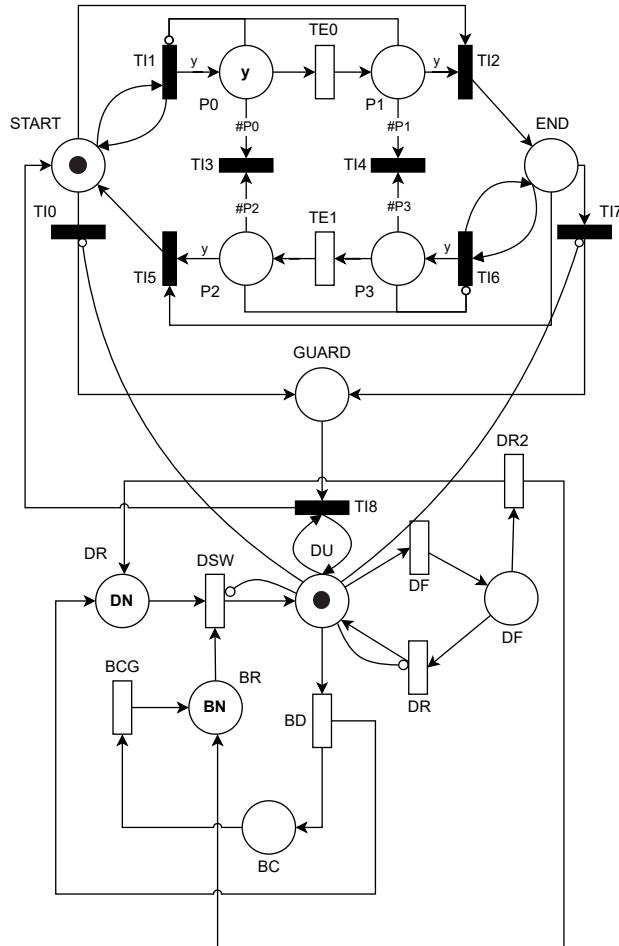
A Figura 18 apresenta o modelo de performabilidade desenvolvido, ilustrando a estrutura da SPN utilizada para representar o sistema de vigilância por drones. O modelo é dividido em duas partes principais: a superior, responsável pela performance em rondas de vigilância por unidade de tempo, e a inferior, que modela a disponibilidade do sistema. Esta estrutura permite uma análise integrada do desempenho e da confiabilidade, capturando as interações complexas entre os diversos componentes do sistema de vigilância.

Ao longo desta seção, detalharemos os componentes do modelo, explicando as funções de cada lugar e transição, bem como as regras que governam suas interações. Apresentaremos também as equações utilizadas para calcular métricas importantes, como a taxa de rondas de vigilância, a disponibilidade do sistema e o tempo de inatividade. Esta abordagem abrangente fornecerá uma base sólida para a avaliação e otimização de sistemas de vigilância por drones, considerando tanto aspectos de performance quanto de disponibilidade.

A parte inferior do modelo consiste em cinco lugares: **DR**, **DU**, **DF**, **BR** e **BC**; seis transições exponenciais temporizadas: **DSW**, **DF**, **DR2**, **BCG**, **BD** e **DR**; e seus arcos. Todas as transições são marcadas independentemente, e suas semânticas de servidor é SSS. Além disso, todas as transições são consideradas prioridade um.

A parte superior do modelo consiste em duas sub-redes do tipo Erlang, compostas pelos lugares **START**, **END**, **P0**, **P1**, **P2** e **P3**; duas transições exponenciais temporizadas: **TE0**

Figura 18 – Modelo de Performabilidade Usando SPN para Sistemas de Vigilância por Drones



Fonte: Elaborado pelo Autor (2024)

e **TE1**; e seis transições imediatas: **TI1**, **TI2**, **TI3**, **TI4**, **TI5** e **TI6**; juntamente com seus arcos. Como na parte inferior, todas as transições têm prioridade um, são marcadas independentemente e têm SSS como suas semânticas de servidor. As transições **TI10**, **TI7** e **TI8** são consideradas transições imediatas, com **TI8** tendo prioridade um, enquanto as outras têm prioridade dois. Elas também seguem Semânticas SSS como suas semânticas de servidor. Estas transições conectam a parte inferior com a parte superior do modelo, juntamente com o lugar **GUARD**.

As sub-redes representam uma distribuição Erlang da forma $Erl(\gamma = y, \lambda = 1/\beta)$. Aqui, γ denota o parâmetro de forma, também conhecido como número de fases, e λ representa o parâmetro de escala correspondente à taxa de cada fase exponencial. Redes de Petri frequentemente representam este último valor como o atraso médio de cada fase.

O tempo de ida (**GOINGTIME**) e o tempo de retorno à base (**BACKTIME**) seguem uma distribuição Erlang de quatro fases ($y = 4$), e a taxa para cada fase é $1/\beta$, onde $\beta = ((GOINGTIME)OR(BACKTIME))/y$, com isto, temos β_0 associado ao tempo **TE0** e β_1 associado ao tempo **TE1**. Optamos por uma configuração de distribuição Erlang de quatro fases para este estudo (**y**) para representar um coeficiente de variação de 0,5 para o tempo. Isso se refere às variáveis que afetam a eficiência operacional dos drones, incluindo, mas não se limitando a, velocidade do vento, condições atmosféricas e outros fatores ambientais. Portanto, os tempos de chegada do drone do ponto A ao ponto B não seguem uma distribuição com taxa constante, nem exibem tanta variação quanto uma distribuição exponencial, que tem um coeficiente de variação de 1.

Em nosso modelo, marcar um token nos lugares **START** e **DU** indica o início do serviço, com um drone ativo patrulhando o perímetro inicial da área de interesse. Essa marcação ativa e dispara a transição **TI1**, que coloca um número **y** de tokens no lugar **P0**. Os tokens são consumidos conforme o atraso atribuído à transição **TE0**, que é disparada uma vez que este tempo é atingido, transferindo os tokens para o lugar **P1**. A transição **TI2** é habilitada e disparada quando vários tokens **y** são encontrados em **P1**, colocando um token no lugar **END** e removendo um token do lugar **START**, representando a chegada do drone ao ponto final da área monitorada. O processo inverso ocorre com outra ronda de monitoramento ao retornar à base e ao perímetro inicial da área de interesse, onde um token é novamente armazenado no lugar.

Esse processo é influenciado pela disponibilidade do sistema, que considera os tempos médios até a falha (**MTTDF**) e o reparo do drone (**MTTDR**), carga (**MTTBC**) e descarga (**MTTBD**) da bateria, e o tempo médio de voo da base até o ponto de observação, representado por (**MTTDS**), sendo modelado na parte inferior do modelo. Quando um token é removido do lugar **DU**, significando que o drone não está mais ativo, seja por falha ou descarga da bateria, as transições **TI3** e **TI4** são habilitadas devido à quebra das expressões de guarda atribuídas a elas. A transição **TI3** contém uma expressão de guarda $((\#P0 > 0)OR(\#P2 > 0))AND(\#DU = 0)$, enquanto a transição **TI4** contém uma expressão de guarda $((\#P1 > 0)OR(\#P3 > 0))AND(\#DU = 0)$. Essas expressões seguem a notação semelhante à do Mercury e são aplicadas ao modelo através do software Mercury.

As expressões de guarda aplicadas às transições **TI3** e **TI4** as habilitam apenas quando o número de tokens nos lugares **P0**, **P2**, **P1** e **P3** é maior que zero, e o lugar **DU** não contém tokens. Além disso, arcos inibidores (arcos com um círculo branco na extremidade) originados

do lugar **DU** também habilitam as transições **T10** e **T17** quando este lugar está vazio. A prioridade das transições **T10** e **T17** permite precedência na ativação sobre as transições **T13** e **T14** com prioridade um, removendo um token dos lugares **START** ou **END** e colocando um token no lugar **GUARD**, representando a interrupção instantânea do serviço de monitoramento devido à indisponibilidade de um componente do sistema. Uma vez habilitadas seguindo a ordem de prioridade, as transições **T13** e **T14** são ativadas e removem um número # de tokens dos lugares **P0**, **P2**, **P1** e **P3**, esvaziando-os, restaurando o processo de monitoramento para uma marcação inicial. Após a recuperação do sistema para uma marcação ativa, significando que há um token no lugar **DU**, um token é removido de **GUARD** e colocado no lugar **START** para reiniciar o monitoramento da base.

Em um sistema básico, o modelo de disponibilidade (parte inferior) opera sem drones e baterias sobressalentes, com zero tokens nos lugares **DR** e **BR**, ou seja, $DN = 0$ e $BN = 0$. Em contraste, um VANT com bateria está ativo, representado por um token no lugar **DU**. Dois arcos inibidores entre as transições **DSW** e **DR** e o lugar **DU** garantem que apenas um VANT possa estar ativo por vez e determinam se um VANT sobressalente ou reparado pode tomar a posição, se atender às condições necessárias. Isso restaura a marcação ativa do sistema de duas maneiras: adicionando um token ao lugar **DU** quando o reparo é concluído na ausência de componentes do drone e baterias sobressalentes ou depositando o drone e a bateria recuperados em seus repositórios para reutilização nos lugares **DR** e **BR**, com um token sendo armazenado em cada lugar. Isso ocorre se a marcação com um drone ativo já foi alcançada antes que o drone com falha seja recuperado por meio de componentes sobressalentes.

As rondas de vigilância realizadas por unidade de tempo são calculadas avaliando a taxa de *throughput* no modelo de desempenho, conforme demonstrado na Equação 4.12. Esta equação utiliza uma notação de expressão semelhante ao Mercury.

$$Tx = (P\{\#START > 0\} \times (1/GOINGTIME)) + (P\{\#END > 0\} \times (1/BACKTIME)), \quad (4.12)$$

onde P representa a probabilidade do sistema conter tokens nos estados **START** e **END**. A derivação do valor final em unidades de tempo envolve dividir as probabilidades pelo tempo total de ida e volta para cada lugar e agrregar os resultados.

Além disso, é possível determinar a disponibilidade do sistema de voo do VANT e sua indisponibilidade e tempo de inatividade por unidade de tempo usando, respectivamente, as

Equações 4.13, 4.14 e 4.15.

$$A = P\{\#DU > 0\}. \quad (4.13)$$

$$UA = 1 - A. \quad (4.14)$$

$$DT = UA \times T \quad (4.15)$$

P calcula a probabilidade do sistema conter tokens no lugar ativo **DU**. Um grafo de alcançabilidade é gerado a partir deste modelo de SPN. Em seguida, o correspondente modelo de CTMC é automaticamente derivado e resolvido usando métodos numéricos (MACIEL et al., 2017).

Embora os modelos propostos neste capítulo forneçam uma base sólida para a análise de confiabilidade, disponibilidade e performabilidade dos sistemas de vigilância com drones, é importante reconhecer algumas limitações e suposições adotadas. Os modelos consideram, por exemplo, taxas de falha constantes e independentes, simplificando o comportamento do sistema, mas pode não refletir todas as variações presentes em cenários reais. Além disso, as condições operacionais foram modeladas com base em um conjunto específico de parâmetros, o que pode limitar a generalização dos resultados para outros contextos. Essas simplificações foram necessárias para viabilizar a construção e a análise dos modelos, porém, seus impactos serão discutidos de forma mais detalhada nos estudos de caso no próximo capítulo. A partir dessa análise, será possível avaliar o alcance dos resultados obtidos e propor aprimoramentos para mitigar as limitações identificadas.

5 ESTUDOS DE CASO

Este capítulo apresenta uma análise do sistema de vigilância baseado em VANTs, explorando os fatores que influenciam sua confiabilidade, disponibilidade e performabilidade. Por meio de dois estudos de caso, investigamos o impacto das variações nos componentes redundantes de baterias e drones, utilizando técnicas de modelagem e análise de sensibilidade. O primeiro estudo de caso foca na avaliação da confiabilidade do sistema, examinando como a redundância de baterias e os tempos médios de carga e descarga afetam o desempenho global ao longo do tempo por meio de um modelo SPN (Modelo 15). O segundo estudo de caso expande a investigação para uma análise de disponibilidade e performabilidade, explorando como o aumento de componentes redundantes influencia métricas como *throughput*, probabilidade de espera por baterias e tempo de inatividade anual por meio de modelos CTMC e SPN (Modelos 13, 14 e 18).

Nossa investigação utiliza uma técnica de diferenciação percentual para conduzir a análise de sensibilidade aplicada a métrica de disponibilidade do sistema, variando sistematicamente um parâmetro de cada vez enquanto mantemos os outros fixos (HAMBY, 1994; ARAUJO et al., 2013; MATOS et al., 2020) (Tabela 4). Este método nos permite quantificar o impacto individual de cada parâmetro na eficiência do sistema. Um aspecto importante deste capítulo é a classificação de sensibilidade desenvolvida, que identifica e hierarquiza os parâmetros mais influentes na disponibilidade do sistema. Esta classificação, apresentada na Tabela 4, oferece *insights* para engenheiros e projetistas, destacando áreas para otimização e melhoria. A Tabela 4 indica que os tempos de descarga da bateria (MTTBD) e os tempos de carregamento (MTTBC) têm o maior impacto na disponibilidade do sistema, seguidos pelo tempo de substituição da bateria do drone (MTTDS). Estes resultados fornecem diretrizes para melhorar a disponibilidade do sistema, sugerindo foco na redução dos tempos relacionados ao MTTBC e MTTDS, bem como no aumento da capacidade de armazenamento das baterias para estender o MTTBD.

Os estudos de caso apresentados neste capítulo utilizam parâmetros selecionados, detalhados nas Tabelas 2, 3 e 5, que refletem configurações de sistemas de vigilância por drones. Ao longo do capítulo, apresentamos análises visuais, incluindo gráficos de superfície e de barras (Figuras 19 a 28), que ilustram as relações entre diversos parâmetros do sistema e suas métricas de desempenho. Estas visualizações oferecem uma compreensão das dinâmicas do sistema

e apoiam a tomada de decisões no design e operação de sistemas de vigilância por VANTs.

Este capítulo valida os modelos teóricos desenvolvidos anteriormente e oferece uma conexão entre a teoria e a prática. Através destes estudos de caso, demonstramos como análises quantitativas podem informar decisões de design e operação em sistemas de vigilância com VANTs, fornecendo *insights* para otimização de recursos, planejamento de redundância e estabelecimento de níveis de serviço. As seções seguintes detalharão cada estudo de caso, apresentando metodologias, resultados e discussões, com o objetivo de fornecer uma compreensão dos fatores que influenciam o desempenho destes sistemas de vigilância baseados em drones.

5.1 ESTUDO DE CASO #1

Este estudo de caso avalia o impacto da redundância de componentes na confiabilidade de um sistema de vigilância por drones, com foco nas baterias. A pesquisa foi motivada pela observação de que o aumento no número de drones sobressalentes não resultava em melhorias notáveis na confiabilidade do sistema durante uma análise transiente de 30 horas. Esta constatação nos levou a direcionar nossa atenção para a redundância das baterias, um componente importante cuja falha pode comprometer a operação do sistema.

Para conduzir esta análise, desenvolvemos um modelo baseado SPN, modelo apresentado no Capítulo 4 como uma adaptação do modelo de disponibilidade. Este modelo incorpora um estado absorvente, como ilustrado na Figura 15, permitindo uma avaliação mais precisa do impacto da redundância da bateria na confiabilidade geral do sistema. Na modelagem do comportamento temporal das baterias, optamos por um modelo Erlang com 10 fases para o parâmetro y . Esta escolha visa um equilíbrio entre precisão e eficiência computacional, após testes que demonstraram que um aumento no número de fases não produzia alterações significativas nos resultados da análise.

Nossa investigação abrangeu três aspectos que influenciam diretamente a confiabilidade do sistema:

1. Número de Baterias Redundantes (**BN**): Variamos de 0 a 20 baterias sobressalentes.
2. Tempo Médio para Carga da Bateria (**MTTBC**): Analisamos cenários com tempos de carga variando de 18 a 180 minutos.

3. Tempo Médio para Descarga da Bateria (**MTTBD**): Consideramos tempos de descarga também no intervalo de 18 a 180 minutos.

Estes parâmetros foram selecionados para refletir uma variedade de cenários operacionais. Em todos os experimentos, mantivemos o número de drones sobressalentes (**DN**) fixo em zero, permitindo-nos isolar e quantificar o efeito da redundância de baterias na confiabilidade do sistema. Os parâmetros relacionados aos tempos-base do modelo são descritos na Tabela 2

Tabela 2 – Parâmetros de Avaliação do Modelo de Confiabilidade.

Parâmetro	Valores (Horas)
$TTSF$	$5,00 \times 10^{-2}$
$MTTBC$	2,00
$MTTBD$	$5,00 \times 10^{-1}$
$MTTDF$	$5,03 \times 10^3$
$MTTDR$	2,00
$MTTDS$	$1,60 \times 10^{-2}$

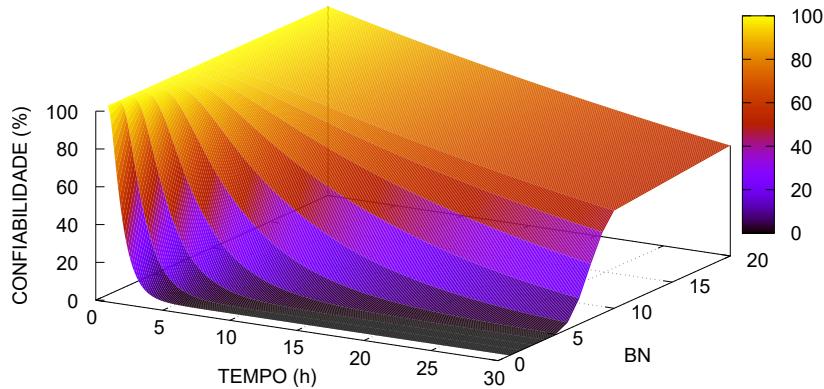
Fonte: Elaborada pelo autor (2024)

Para a execução dos experimentos, utilizamos o software Mercury, uma ferramenta para análise de modelos SPN (MACIEL et al., 2017). A confiabilidade do sistema foi avaliada através da expressão $P\{\#SF = 0\}$, que calcula a probabilidade de não haver tokens no lugar **SF**, representando assim a probabilidade de o sistema não entrar em estado de falha durante o período de operação analisado.

Os resultados desta análise são apresentados nas Figuras 19, 20 e 21, que ilustram respectivamente o impacto do número de baterias redundantes, do tempo de carga e do tempo de descarga na confiabilidade do sistema ao longo do tempo. Estas visualizações fornecem informações sobre como otimizar a configuração do sistema para melhorar sua confiabilidade em diferentes cenários operacionais.

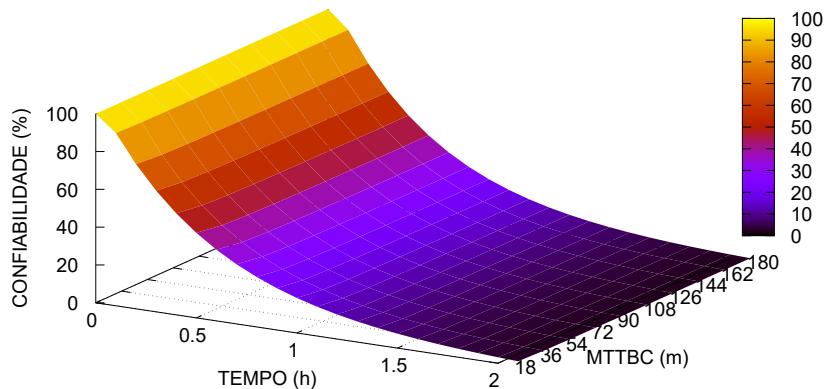
A Figura 19 ilustra o impacto do número de baterias redundantes na confiabilidade do sistema ao longo de 30 horas. Os resultados indicam que com 15-20 baterias redundantes, o sistema mantém a confiabilidade acima de 80% por quase todo o período. Em contraste, com 0-5 baterias, a confiabilidade cai rapidamente para menos de 20% em poucas horas. Estes resultados demonstram claramente a importância crítica da redundância de baterias para missões de longa duração.

Figura 19 – Relação entre Confiabilidade do Sistema, Tempo de Operação e Número de Baterias Redundantes (BN) durante um Período de 30 Horas



Fonte: Elaborado pelo Autor (2024)

Figura 20 – Impacto do Tempo Médio de Carga da Bateria (MTTBC) na Confiabilidade do Sistema Durante 2 Horas de Operação

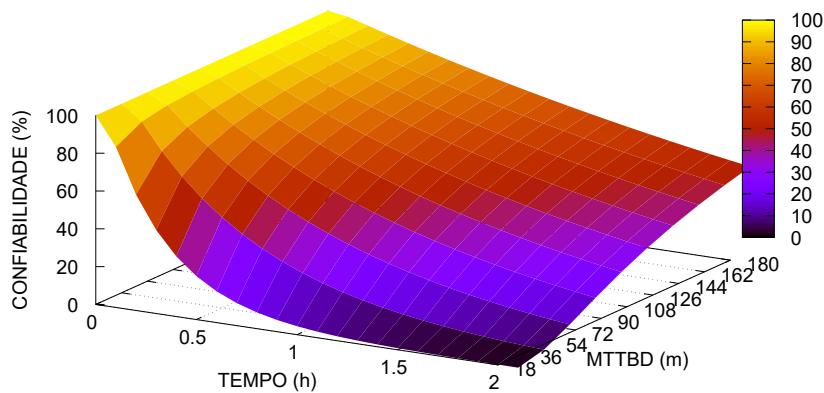


Fonte: Elaborado pelo Autor

A Figura 20 apresenta a relação entre o Tempo Médio de Carga da Bateria (MTTBC) e a confiabilidade do sistema durante 2 horas de operação. Observa-se um padrão interessante na relação entre MTTBC e confiabilidade. Para um MTTBC de 18 minutos, a confiabilidade do sistema começa em 100%, cai para aproximadamente 40% em 30 minutos e chega a zero após 2 horas de operação. Notavelmente, o aumento do MTTBC de 18 minutos até 180 minutos não apresenta impacto significativo na curva de confiabilidade, com as curvas para diferentes

valores de MTTBC neste intervalo permanecendo muito próximas. Estes dados sugerem que, uma vez que o MTTBC atinge um certo limiar (neste caso, 18 minutos), melhorias adicionais no tempo de carga têm pouco efeito na confiabilidade do sistema ao longo do tempo de operação analisado.

Figura 21 – Efeito do Tempo Médio de Descarga da Bateria (MTTBD) na Confiabilidade do Sistema ao Longo de 2 Horas de Operação.



Fonte: Elaborado pelo Autor (2024)

A Figura 21 demonstra o efeito do Tempo Médio para Descarga da Bateria (MTTBD) na confiabilidade do sistema, também durante 2 horas de operação. Nota-se uma relação direta entre MTTBD e confiabilidade. Com um MTTBD de 180 minutos, o sistema mantém a confiabilidade acima de 60% durante todo o período. Em contraste, com um MTTBD de 36 minutos, a confiabilidade diminui drasticamente, atingindo menos de 20% após 1 hora de operação. Estes resultados enfatizam a necessidade de baterias de alta capacidade ou estratégias de otimização de consumo de energia para prolongar o tempo de operação confiável.

Estes resultados demonstram que a confiabilidade do sistema é altamente sensível a múltiplos fatores, sendo o número de baterias redundantes crucial para missões de longa duração, enquanto os tempos de carga e descarga da bateria são críticos para a confiabilidade em períodos mais curtos. Para otimizar o sistema, recomenda-se manter um número adequado de baterias redundantes, idealmente entre 15 e 20 para missões de 30 horas, como indicado na Figura 19. Adicionalmente, minimizar o tempo de carga da bateria para menos de 36 minutos (Figura 20) e usar baterias com tempos de descarga superiores a 144 minutos (Figura 21) são estratégias aconselháveis para melhorar o desempenho geral do sistema.

Para ilustrar uma aplicação prática deste estudo, consideremos um cenário de vigilância urbana, onde uma empresa utiliza drones para monitorar um festival de música ao ar livre com duração de 4 horas. Baseando-se nos resultados da pesquisa, a empresa pode implementar uma estratégia eficaz utilizando aproximadamente 10 baterias redundantes, o que manterá uma confiabilidade do sistema acima de 80% durante todo o evento. Esta abordagem representa uma otimização significativa de recursos em comparação com as 15-20 baterias que seriam necessárias para missões mais longas, de 30 horas, permitindo uma redução de custos sem comprometer a eficácia da operação.

O estudo também fornece diretrizes valiosas para os parâmetros de carga e descarga das baterias. Um tempo médio de carga de bateria (MTTBC) de cerca de 20 minutos mostra-se suficiente, eliminando a necessidade de investimentos em sistemas de carga mais rápidos e potencialmente mais caros. Ademais, a empresa deve priorizar a utilização de drones equipados com baterias que possuam um tempo médio de descarga (MTTBD) de pelo menos 180 minutos, assegurando que cada drone possa operar por um período substancial antes de necessitar substituição.

Com base nessas recomendações, a empresa pode estabelecer um sistema de rotação eficiente, onde drones com baterias completamente carregadas substituem aqueles cujas baterias estão se esgotando, garantindo uma cobertura ininterrupta do evento. Esta estratégia não apenas assegura uma alta confiabilidade do sistema durante as 4 horas do festival, mas também otimiza os custos operacionais. Adicionalmente, tal configuração oferece a flexibilidade necessária para estender o monitoramento por algumas horas extras, se preciso, exemplificando como a análise detalhada da confiabilidade do sistema pode ser traduzida em benefícios práticos e econômicos em cenários reais de segurança e vigilância urbana.

Ao implementar essas recomendações, os projetistas de sistemas de vigilância por drones podem equilibrar efetivamente a duração da missão, a confiabilidade do sistema e os recursos disponíveis. As análises apresentadas nas Figuras 19, 20 e 21 fornecem *insights* valiosos para otimizar o desempenho do sistema sob várias condições e durações de missão. Essas estratégias, quando aplicadas coletivamente, podem resultar em um sistema de vigilância por drones mais robusto e confiável, capaz de operar eficientemente em uma ampla gama de cenários, aumentando, em última análise, a eficácia geral das operações de vigilância baseadas em drones.

É importante notar algumas limitações deste estudo. O modelo assume taxas de falha e reparo constantes, o que pode não refletir precisamente o comportamento real dos componentes

ao longo do tempo. Além disso, não consideramos fatores ambientais como temperatura ou condições climáticas, que podem afetar o desempenho das baterias. A análise também focou apenas na redundância de baterias, não considerando outros componentes que podem falhar.

Para futuras pesquisas, seria valioso expandir o modelo para incluir a redundância de outros componentes críticos, como sensores e sistemas de comunicação. Além disso, a incorporação de fatores ambientais e a consideração de taxas de falha e reparo variáveis ao longo do tempo poderiam fornecer uma visão mais realista e abrangente da confiabilidade do sistema em diferentes condições operacionais.

5.2 ESTUDO DE CASO #2

Este estudo de caso avalia o impacto da redundância e melhorias de componentes na disponibilidade e performabilidade de um sistema de vigilância por drones, com foco particular nas baterias e nos tempos médios do sistema. Os experimentos foram motivados pela observação inicial de que o aumento no número de drones sobressalentes não resultava em melhorias significativas na disponibilidade do sistema durante análises preliminares. Esta constatação nos levou a direcionar nossa atenção para a redundância das baterias e outros parâmetros temporais críticos, componentes essenciais cuja otimização pode substancialmente melhorar a performance e a disponibilidade do sistema.

Para conduzir esta análise, desenvolvemos e aplicamos dois modelos complementares:

1. Um modelo de disponibilidade baseado em SPN, apresentado na Figura 14 do Capítulo 4. Este modelo nos permite avaliar como diferentes configurações de redundância e tempos médios afetam a disponibilidade do sistema.
2. Um modelo de performabilidade, também baseado em SPN, que incorpora o tempo de cobertura (CoV_{time}) calculado a partir do nosso modelo de cobertura. Este modelo, ilustrado na Figura 18 do Capítulo 4, nos permite analisar métricas de desempenho como *throughput* e probabilidade de espera por baterias.

Na modelagem do comportamento temporal dos componentes, optamos por distribuições exponenciais para os tempos de falha e reparo, uma escolha que busca equilibrar precisão e tratabilidade computacional.

Nossa investigação abrangeu vários aspectos que influenciam a confiabilidade, disponibilidade e performabilidade do sistema:

- Número de Baterias Redundantes (**BN**): Variamos de 1 a 12 baterias sobressalentes.
- Tempo Médio para Carga da Bateria (**MTTBC**): Analisamos cenários com tempos de carga variando de 30 a 180 minutos.
- Tempo Médio para Descarga da Bateria (**MTTBD**): Consideramos tempos de descarga também no intervalo de 30 a 180 minutos.
- Tempo de Cobertura (CoV_{time}): Incorporamos este parâmetro, derivado do modelo de dimensionamento, para refletir o tempo necessário para o drone cobrir a área de vigilância designada.

Estes parâmetros foram selecionados para refletir uma variedade de cenários operacionais. Em todos os experimentos, mantivemos o número de drones sobressalentes (DN) fixo, permitindo-nos isolar e quantificar o efeito da redundância de baterias e dos tempos médios do sistema na confiabilidade, disponibilidade e performabilidade.

Para a execução dos experimentos, utilizamos o software Mercury, uma ferramenta para análise de modelos SPN (MACIEL et al., 2017). Avaliamos métricas como disponibilidade do sistema, *throughput* (medido em rondas de vigilância por hora), probabilidade de espera por baterias e tempo médio de inatividade anual.

Tabela 3 – Parâmetros de Dimensionamento do Sistema de Vigilância por Drone

Parâmetro	Valores
FL	4,89 mm
CS_h	3,816 mm
CS_w	6,780 mm
R_h	1080 px
O_{real}	1,70 m
O_{img}	31 px
H_{max}	32,17 m
A_l	124 m
A_w	130 m
D_{speed}	3 m/s

Fonte: Elaborada pelo autor (2024)

Os parâmetros de dimensionamento do VANT selecionado para os experimentos subsequentes foram determinados com base nas configurações típicas de câmera e velocidade de um drone comercial convencional. Além disso, para os experimentos seguintes, assumimos que este sistema monitora uma área para detectar a entrada e saída de pessoas na área. Neste contexto, consideramos um ser humano com uma altura média de 1,7 metros (O_{real}) e um requisito mínimo de 31 pixels na imagem capturada (O_{img}). Também estamos considerando uma área de vigilância equivalente às dimensões da área de validação utilizada, 124 metros de comprimento (A_l) e 130 metros de largura (A_w) (Tabela 3).

Calculamos o parâmetro CoV_{time} através do dimensionamento e o utilizamos como entrada para alimentar o modelo de SPN. Os outros valores dos parâmetros iniciais utilizados nos experimentos estão detalhados na Tabela 5.

A seguir, apresentamos estudos de caso baseados em uma análise de sensibilidade dos componentes do sistema, visando identificar aqueles com maior grau de criticidade (Tabela 4). A análise utilizou uma técnica de diferenciação percentual descrita na Equação 2.12. Adicionalmente, fornecemos uma classificação de sensibilidade demonstrando o impacto de cada parâmetro na métrica de *disponibilidade* do sistema. Esta métrica interfere na métrica de *throughput* do sistema, representado pelo número de voltas que o drone realiza por minuto e está detalhada na Tabela 5.

Tabela 4 – Classificação de Sensibilidade

Parâmetro	Classificação	Índice de sensibilidade
<i>MTTBD</i>	1º	$5,694 \times 10^{-1}$
<i>MTTBC</i>	2º	$5,396 \times 10^{-1}$
<i>MTTDS</i>	3º	$6,601 \times 10^{-3}$
<i>MTTDF</i>	4º	$5,304 \times 10^{-5}$
<i>MTTDR</i>	5º	$3,508 \times 10^{-5}$

Fonte: Elaborada pelo autor (2024)

A Tabela 4 indica que os tempos de descarga da bateria (**MTTBD**) e os tempos de carga (**MTTBC**) têm o maior impacto na disponibilidade do sistema. O terceiro fator mais importante é o tempo de substituição da bateria do drone (**MTTDS**). Para melhorar a disponibilidade, engenheiros e projetistas de sistemas devem se concentrar em reduzir os tempos relacionados ao **MTTBC** e **MTTDS**, adquirindo equipamentos melhores, como carregadores de bateria de maior eficiência e drones mais ágeis. Baterias com maior capacidade de

Tabela 5 – Parâmetros de Avaliação de Performabilidade

Parâmetro	Valores (Horas)
CoV_{time}	$4,82 \times 10^{-2}$
$MTTBC$	2,00
$MTTBD$	$5,00 \times 10^{-1}$
$MTTDF$	$5,03 \times 10^3$
$MTTDR$	2,00
$MTTDS$	$1,60 \times 10^{-2}$

Fonte: Elaborada pelo autor (2024)

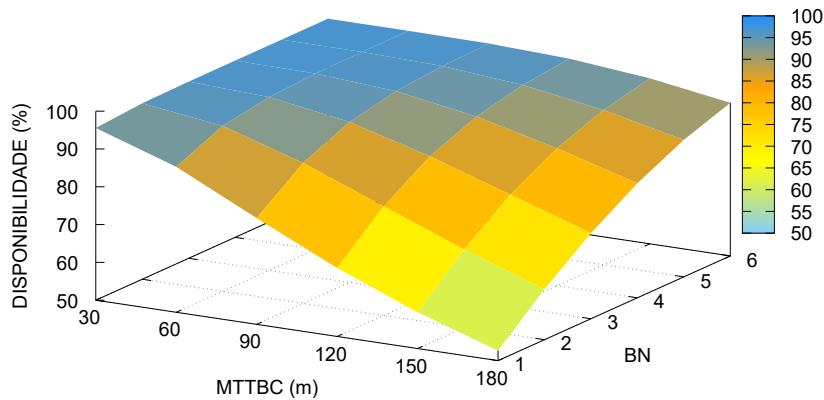
armazenamento também podem estender o período (**MTTBD**).

Neste estudo de caso, investigamos os fatores que impactam a disponibilidade de sistemas de drones de vigilância, focando especificamente no gerenciamento de baterias e peças sobressalentes. Por meio de análise estacionária, avaliamos a influência de MTTBC, MTTBD e BN na disponibilidade. O objetivo principal é auxiliar engenheiros e gestores na otimização do projeto e operação do sistema, identificando estratégias para garantir alta disponibilidade em vários cenários. Os gráficos ilustram claramente o impacto desses parâmetros na disponibilidade operacional, oferecendo insights valiosos para melhorar o desempenho e a eficiência dos sistemas de drones de vigilância.

A Figura 22 ilustra o impacto do MTTBC, evidenciando uma clara relação inversa entre o tempo de carregamento e a disponibilidade do sistema. À medida que o MTTBC aumenta, a disponibilidade diminui, particularmente com menos baterias sobressalentes. Por exemplo, com um MTTBC de 30 minutos e BN=3, a disponibilidade varia de 90-100%. No entanto, quando o MTTBC aumenta para 120 minutos mantendo BN=3, a disponibilidade cai para 80-90%. Esta tendência indica que investimentos em tecnologias de carregamento podem impactar significativamente a disponibilidade operacional.

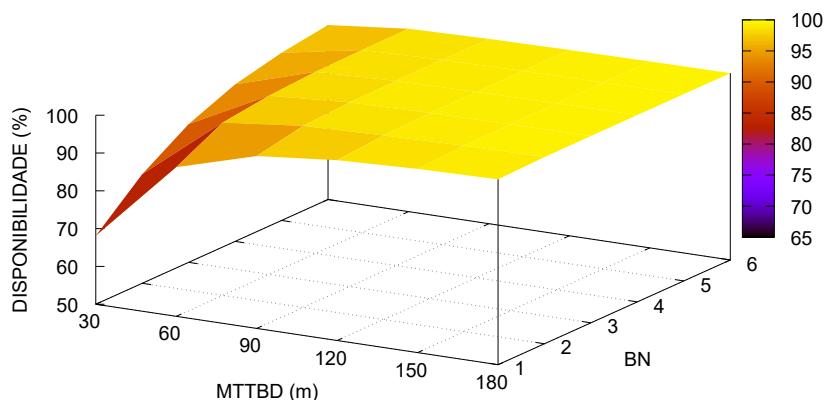
A Figura 23, focada no MTTBD, mostra uma tendência oposta e mais pronunciada - aumentos no MTTBD resultam em melhorias substanciais na disponibilidade do sistema. Com MTTBD de 30 minutos e BN=3, a disponibilidade está na faixa de 70-80%. No entanto, aumentando o MTTBD para 90 minutos enquanto mantém BN=3, a disponibilidade sobe para 90-100%. Notavelmente, com um MTTBD de 180 minutos, mesmo com apenas duas baterias sobressalentes (BN=2), é possível manter 90-100% de disponibilidade. Esses dados indicam que investir em baterias de maior duração pode ser uma estratégia altamente eficaz para melhorar a disponibilidade do sistema.

Figura 22 – Impacto do Tempo Médio de Carregamento da Bateria (MTTBC) e do Número de Baterias Sobressalentes (BN) na Disponibilidade do Sistema de Drones.



Fonte: Elaborado pelo Autor (2024)

Figura 23 – Impacto do Tempo Médio de Descarga da Bateria (MTTBD) e do Número de Baterias Sobressalentes (BN) na Disponibilidade do Sistema de Drones.



Fonte: Elaborado pelo Autor (2024)

A análise comparativa dos dois gráficos revela que melhorias no MTTBD têm um impacto mais positivo e imediato na disponibilidade do sistema do que reduções equivalentes no MTTBC. Por exemplo, para um cenário com $BN=3$ e tempo de 120 minutos, o gráfico MTTBC mostra uma disponibilidade de 80-90%, enquanto o gráfico MTTBD indica uma disponibilidade de 90-100% para os mesmos parâmetros.

Os gráficos permitem identificar áreas de otimização onde se pode alcançar um equilíbrio

ideal entre os parâmetros. No gráfico MTTBC, a zona ótima está entre 60-90 minutos com BN=3-4, mantendo a disponibilidade em 90-100%. No gráfico MTTBD, quase toda a área com MTTBD superior a 90 minutos e BN igual ou superior a três oferece disponibilidade máxima.

Ambos os gráficos exibem pontos de inflexão. No gráfico MTTBC, um aumento de BN de 3 para 4, com um tempo de carga de 150 minutos, leva a um aumento na disponibilidade de 70-80% para 80-90%. Por outro lado, no gráfico MTTBD, a mudança de 80-90% para 90-100% de disponibilidade ocorre rapidamente à medida que o tempo de descarga passa de 60 para 90 minutos, com BN=3.

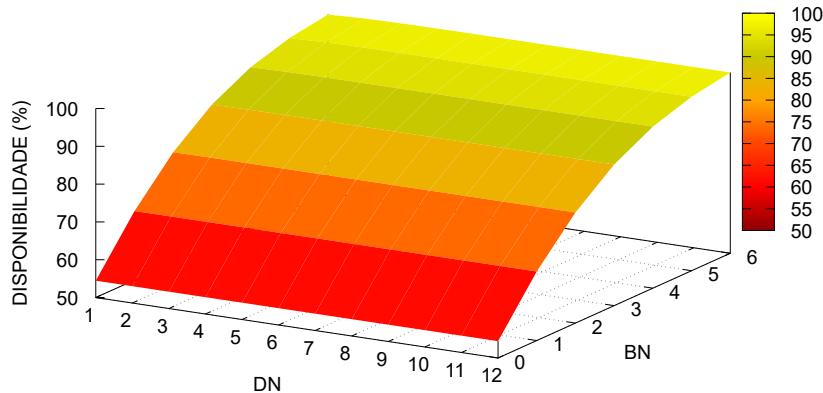
Em conclusão, os resultados sugerem que, embora reduzir o tempo de carregamento seja benéfico, investir em baterias de maior duração e aumentar o número de baterias sobressalentes pode oferecer melhorias mais significativas na disponibilidade do sistema. Essas percepções são cruciais para otimizar o projeto de sistemas de drones e equilibrar custos, eficiência operacional e disponibilidade.

No entanto, a Figura 24 retrata a influência do número de drones (DN) e baterias sobressalentes (BN) na disponibilidade do sistema, em vez dos gráficos 22 e 23, que destacam os impactos significativos de MTTBC, MTTBD e BN na disponibilidade. O gráfico 24 indica uma tendência clara. Neste cenário, deve-se enfatizar que um aumento nos drones sobressalentes não leva a melhorias substanciais na disponibilidade do sistema. Isso se deve aos baixos tempos de manutenção e ao alto tempo médio até a falha (MTTDF) dos drones.

Os dados representados no gráfico ilustram que adicionar mais baterias sobressalentes tem um impacto significativamente mais positivo na disponibilidade do sistema do que adicionar drones sobressalentes. A disponibilidade do sistema tende a atingir um platô após um certo limite de componentes redundantes, não mostrando melhorias substanciais além desse ponto. Vale ressaltar que com apenas cinco baterias sobressalentes, o sistema atinge uma impressionante disponibilidade de 96,74%, enquanto adicionar mais drones sobressalentes não proporciona benefícios adicionais significativos.

Adicionalmente, focamos também em explorar o impacto da redundância de baterias no desempenho e disponibilidade do sistema de vigilância por drones. As Figuras 25, 26, 27 e 28 ilustram os principais resultados deste estudo, fornecendo insights significativos para o planejamento e otimização do sistema. As Figuras 25 à 27 mostram três gráficos críticos: o *throughput* do sistema medido em rondas de vigilância por hora, a probabilidade do drone esperar por baterias, Probability of Drone Waiting for Batteries (PDWB) e o número médio

Figura 24 – Impacto do Número de Drones (DN) e Baterias Sobressalentes (BN) na Disponibilidade do Sistema de Drones.



Fonte: Elaborado pelo Autor (2024)

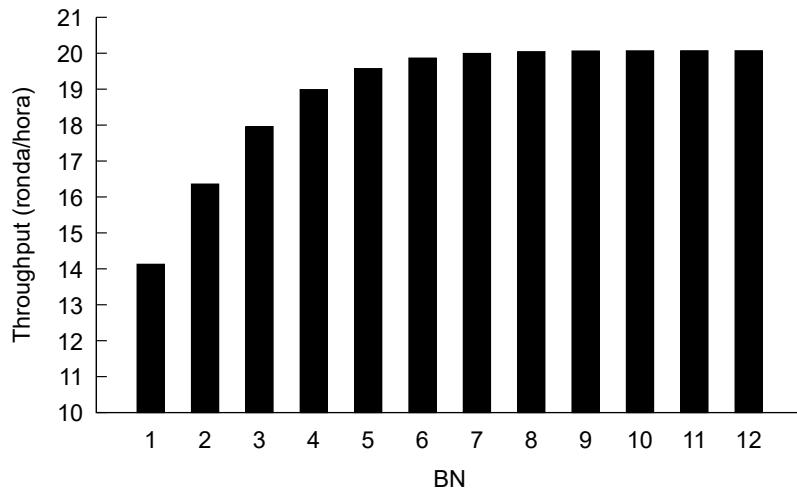
de baterias disponíveis, Average Number of Batteries Available (AVGBA). Adicionalmente, a Figura 28 apresenta o tempo de inatividade anual do sistema em horas (DTyd).

Integrar os modelos de cobertura e performabilidade para uma análise completa é essencial. O modelo de cobertura permite aos analistas determinar a altura máxima de operação do drone e a área que ele pode cobrir em uma única passagem, considerando as dimensões do alvo monitorado, a resolução da câmera e o FOV. Por exemplo, ao considerar um alvo humano com 1,75m de altura, exigindo uma representação de 150 pixels na imagem, e usando uma câmera com resolução de 1920x1080 pixels, o modelo de cobertura calcula a altura máxima de voo e o FOV correspondente. Esses parâmetros afetam diretamente o tempo de cobertura da área monitorada (CoV_{time}).

O modelo de performabilidade considera o CoV_{time} um fator crítico. Ele é calculado com base no campo de visão do drone (FOV), velocidade média e área que precisa monitorar. Por exemplo, se o CoV_{time} for determinado como 10 minutos para uma área de 100x100m, esse valor é então utilizado no modelo de Rede de Petri para estabelecer a duração de cada ciclo de vigilância. Portanto, este parâmetro, derivado do modelo de cobertura, impacta diretamente o *throughput* do sistema, medido em rondas de vigilância por hora (ver Figura 25).

Os resultados do modelo de performabilidade ilustram uma clara relação entre o aumento de baterias sobressalentes (BN) e a melhoria no desempenho do sistema. Com BN aumentando de 1 para 6, há um notável aumento no *throughput*, subindo de aproximadamente 10 para 17

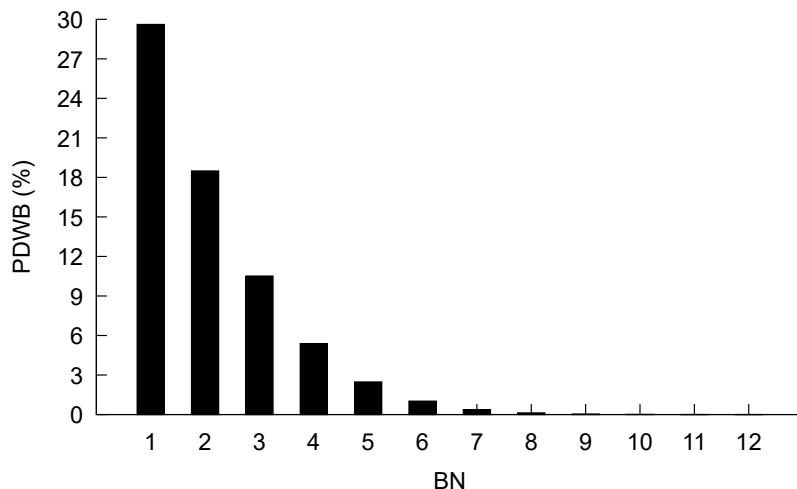
Figura 25 – Rondas de Vigilância Realizadas por Hora pelo Drone.



Fonte: Elaborado pelo Autor (2024)

rondas por hora (Fig. 25). Simultaneamente, PDWB vê uma queda acentuada, caindo de cerca de 25% para menos de 5% (Fig. 26). Enquanto isso, o AVGBA aumenta de 1 para quase 5 (Fig. 27). Este avanço reflete diretamente na redução do tempo de inatividade anual (DTyd), diminuindo de aproximadamente 100 horas para menos de 20 horas anualmente (Fig. 28).

Figura 26 – Probabilidade do Drone Esperar pelas Baterias.

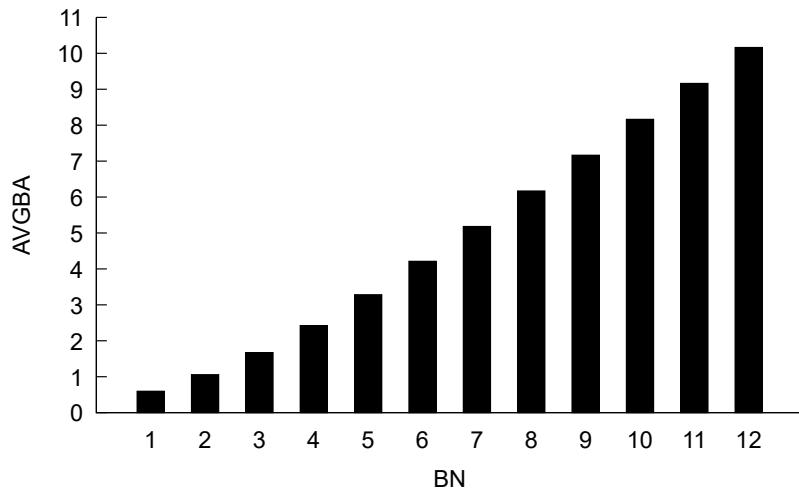


Fonte: Elaborado pelo Autor (2024)

A interação entre os modelos de cobertura e performabilidade permite uma otimização mais precisa do sistema. Por exemplo, se uma mudança nos atributos do alvo ou na resolução da câmera aumentar o CoV_{time} de 10 para 15 minutos, o modelo de performabilidade pode ser rapidamente recalibrado para considerar este ajuste. Esta adaptação permitiria aos gestores

avaliar as repercussões desta modificação no *throughput* do sistema e discernir se baterias extras são necessárias para manter o nível de serviço estipulado.

Figura 27 – Número Médio de Baterias Disponíveis.



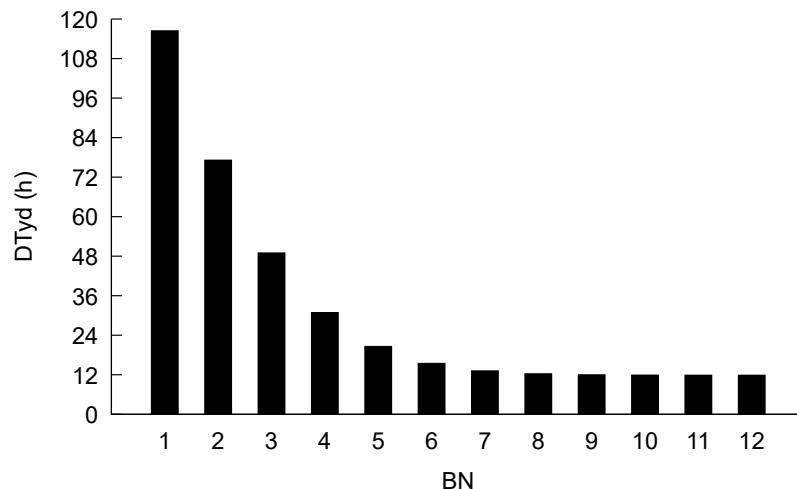
Fonte: Elaborado pelo Autor (2024)

É essencial utilizar estes dados integrados para otimizar vários aspectos do sistema. Para atingir o objetivo operacional de 16 rondas por hora, o CoV_{time} calculado sugere que consultar os dados na Fig. 25 pode ajudar a determinar o número necessário de baterias sobressalentes, permitindo um planejamento preciso. Para manter um PDWB máximo de 5% conforme Acordo de Nível de Serviço, Service Level Agreement (SLA), a Figura 26 indica a necessidade de pelo menos sete baterias sobressalentes, possibilitando o estabelecimento de SLAs realistas e alcançáveis. Adicionalmente, para reduzir o tempo de inatividade anual para menos de 24 horas, a Fig. 28 propõe que seis baterias sobressalentes seriam necessárias, facilitando um planejamento mais eficiente das janelas de manutenção.

Os dados indicam que passar de 8 para 9 baterias leva apenas a pequenas melhorias de desempenho, sugerindo um ponto crítico em um processo de retornos decrescentes. Esta percepção é essencial para tomar decisões informadas sobre investimentos em redundância. Ao planejar um aumento de 20% no *throughput*, as informações na Figura 25 permitem o cálculo preciso das baterias adicionais necessárias, facilitando o planejamento estratégico de recursos para expansão futura. Por exemplo, aumentar BN de 10 para 12 mostra melhorias mínimas em todos os parâmetros, sugerindo que investimentos adicionais além deste limiar podem não ser justificáveis.

É importante notar algumas limitações deste estudo. Os modelos assumem distribuições exponenciais para os tempos de falha e reparo, podendo não representar precisamente o com-

Figura 28 – Análise do Tempo de Inatividade Anual do Sistema (DTyd) em Relação ao Número de Baterias Sobressalentes.



Fonte: Elaborado pelo Autor (2024)

portamento real dos componentes. Não consideramos a degradação das baterias ao longo do tempo, o que poderia afetar o desempenho em longo prazo. Além disso, a análise não considera variações nas condições operacionais, como diferentes perfis de missão ou condições ambientais.

Essas análises ilustram a importância da modelagem de performabilidade na melhoria da eficiência dos sistemas de vigilância por drones. Ao oferecer *insights* quantitativos sobre os efeitos da redundância de baterias, o modelo facilita a tomada de decisões bem informadas que equilibram desempenho, disponibilidade e custo. Melhorar a eficiência operacional estabelece uma base sólida para planejamento estratégico, gerenciamento de riscos e alocação de recursos.

6 CONCLUSÕES

Este trabalho apresentou uma abordagem abrangente para avaliar sistemas de vigilância baseados em VANTs utilizando modelos estocásticos avançados. O objetivo principal de desenvolver modelos para otimização de sistemas de vigilância com drones, integrando análises de confiabilidade, disponibilidade e performabilidade, foi alcançado com sucesso. Estes modelos integraram fatores críticos como área de vigilância, resolução da câmera, restrições de altitude, gerenciamento de bateria, falhas e reparos, avaliados por meio de CTMCs e SPNs. Em relação aos objetivos secundários, conseguimos melhorar significativamente a autonomia da bateria e gerenciar eficazmente aspectos operacionais como tempos de carregamento e tempos de trocas de drones no sistema. Os estudos de caso apresentados validaram a eficácia dos modelos na melhoria do desempenho da vigilância de VANTs, fornecendo *insights* valiosos para otimização de sistemas.

Nossa metodologia, que incorporou análises de sensibilidade para identificar componentes críticos e avaliar o impacto das redundâncias no desempenho do sistema, revelou descobertas significativas. Notavelmente, a redundância de baterias demonstrou ter um impacto substancial na disponibilidade e confiabilidade do sistema, superando a redundância de drones. O MTTBC e o MTTBD foram identificados como fatores críticos que afetam diretamente o desempenho do sistema. Os resultados dos estudos de caso forneceram diretrizes práticas valiosas para projetistas e engenheiros de sistemas de vigilância por drones. Para missões de longa duração (30 horas), descobrimos que manter entre 15 e 20 baterias redundantes pode garantir uma confiabilidade acima de 80%. Além disso, otimizar o tempo de carregamento da bateria para menos de 36 minutos e usar baterias com tempos de descarga superiores a 144 minutos pode melhorar significativamente a confiabilidade do sistema. Estas descobertas têm implicações diretas para o desenvolvimento de sistemas mais robustos e confiáveis.

É importante, no entanto, reconhecer algumas limitações deste estudo. Os modelos assumem taxas de falha e reparo constantes, podendo não refletir precisamente o comportamento real dos componentes ao longo do tempo. Além disso, não consideramos fatores ambientais como temperatura ou condições climáticas, que podem afetar o desempenho das baterias. A análise também focou na redundância de baterias, não considerando outros componentes que podem falhar. As implicações práticas deste trabalho são significativas. Os modelos desenvolvidos podem ser aplicados por engenheiros e gestores para otimizar o planejamento de sistemas

de vigilância, equilibrando efetivamente o desempenho aprimorado com considerações de custo. Por exemplo, as descobertas sobre o número ideal de baterias redundantes e os tempos ótimos de carga e descarga podem informar decisões de compra e manutenção, potencialmente reduzindo custos operacionais enquanto mantém alta confiabilidade do sistema.

Para trabalhos futuros, sugerimos expandir o modelo para incluir fatores ambientais e condições climáticas que afetem o desempenho dos drones. Seria particularmente relevante investigar o impacto de diferentes tecnologias de bateria na disponibilidade e confiabilidade do sistema. Além disso, o desenvolvimento de um modelo que considere a possibilidade de múltiplos drones ativos simultaneamente na área-alvo poderia fornecer *insights* valiosos para operações de vigilância em larga escala. Outra área promissora para pesquisas futuras é a análise do impacto de falhas de comunicação entre o drone e a base na disponibilidade do serviço. Isso poderia levar ao desenvolvimento de estratégias mais robustas para manter a continuidade operacional em cenários de comunicação degradada. Adicionalmente, o desenvolvimento de algoritmos de otimização capazes de recomendar configurações ideais do sistema com base em requisitos de desempenho definidos - como cobertura máxima da área de vigilância e consumo mínimo de energia - e restrições, como limitações de altitude e vida útil da bateria, agregaria valor prático significativo à nossa abordagem.

Em conclusão, nossa abordagem representa um avanço significativo no campo dos sistemas de vigilância baseados em VANTs. Ao abordar desafios-chave e fornecer *insights* açãoáveis, nossa pesquisa contribui para a otimização de fluxos de trabalho operacionais, mitigação de riscos e alcance de resultados sustentáveis em diversas aplicações. As direções de pesquisa propostas podem contribuir significativamente para o desenvolvimento de sistemas de vigilância por drones mais eficientes, confiáveis e adaptáveis para várias condições operacionais, impulsionando avanços neste campo em rápida evolução. Explorar estratégias de otimização para equilibrar custo, desempenho e confiabilidade na implementação de redundâncias seria valioso, assim como investigar a integração de fontes alternativas de energia, como carregamento solar, para aumentar a autonomia dos drones, abrindo novas possibilidades para melhorar a eficiência e sustentabilidade desses sistemas. Estas direções de pesquisa não apenas expandirão o escopo do trabalho atual, mas também fornecerão uma base sólida para o desenvolvimento contínuo e a inovação no campo dos sistemas de vigilância baseados em VANTs.

REFERÊNCIAS

- ABUSHAHMA, R. I. H.; ALI, M. A.; RAHMAN, N. A. A.; AL-SANJARY, O. I. Comparative features of unmanned aerial vehicle (uav) for border protection of libya: a review. In: IEEE. *2019 IEEE 15th International Colloquium on Signal Processing & Its Applications (CSPA)*. [S.I.], 2019. p. 114–119.
- AHMED, F.; MOHANTA, J.; KESHARI, A.; YADAV, P. S. Recent advances in unmanned aerial vehicles: a review. *Arabian Journal for Science and Engineering*, Springer, v. 47, n. 7, p. 7963–7984, 2022.
- AIRDATA. *Drone Data Management and Flight Analysis | Airdata UAV*. 2024. [Online; accessed 21. Feb. 2025]. Disponível em: <<https://airdata.com>>.
- ALHAFNAWI, M.; SALAMEH, H. B.; MASADEH, A.; AL-OBIEDOLLAH, H.; AYYASH, M.; EL-KHAZALI, R.; ELGALA, H. A survey of indoor and outdoor uav-based target tracking systems: Current status, challenges, technologies, and future directions. *IEEE Access*, IEEE, 2023.
- ARAUJO, J.; ALVES, V.; OLIVEIRA, D.; DIAS, P.; SILVA, B.; MACIEL, P. An investigative approach to software aging in android applications. In: IEEE. *2013 IEEE international conference on systems, man, and cybernetics*. [S.I.], 2013. p. 1229–1234.
- AVIZIENIS, A.; LAPRIE, J.-C.; RANDELL, B. et al. Fundamental concepts of dependability. *Technical Report Series-University of Newcastle upon Tyne Computing Science*, University of Newcastle upon Tyne, 2001.
- AVIZIENIS, A.; LAPRIE, J.-C.; RANDELL, B.; LANDWEHR, C. Basic concepts and taxonomy of dependable and secure computing. *IEEE transactions on dependable and secure computing*, IEEE, v. 1, n. 1, p. 11–33, 2004.
- BOLCH, G.; GREINER, S.; MEER, H. D.; TRIVEDI, K. S. *Queueing networks and Markov chains: modeling and performance evaluation with computer science applications*. [S.I.]: John Wiley & Sons, 2006.
- BRITO, C.; SILVA, L.; CALLOU, G.; NGUYEN, T. A.; MIN, D.; LEE, J.-W.; SILVA, F. A. Offloading data through unmanned aerial vehicles: a dependability evaluation. *Electronics*, MDPI, v. 10, n. 16, p. 1916, 2021.
- CASSANDRAS, C. G.; LAFORTUNE, S. *Introduction to discrete event systems*. [S.I.]: Springer, 2008.
- CHITTOOR, P. K.; CHOKKALINGAM, B.; MIHET-POPA, L. A review on uav wireless charging: Fundamentals, applications, charging techniques and standards. *IEEE access*, IEEE, v. 9, p. 69235–69266, 2021.
- DASHWARE. *Download DashWare by GoPro, Inc.* 2024. [Online; accessed 21. Feb. 2025]. Disponível em: <<https://dashware.software.informer.com/download>>.
- DUI, H.; ZHANG, C.; BAI, G.; CHEN, L. Mission reliability modeling of uav swarm and its structure optimization based on importance measure. *Reliability Engineering & System Safety*, Elsevier, v. 215, p. 107879, 2021.

- FALCÃO, M.; SOUZA, C. B.; BALIEIRO, A.; DIAS, K. Resource allocation for uav-enabled multi-access edge computing. *The Journal of Supercomputing*, Springer, v. 80, n. 15, p. 22770–22802, 2024.
- FENG, Q.; LIU, M.; DUI, H.; REN, Y.; SUN, B.; YANG, D.; WANG, Z. Importance measure-based phased mission reliability and uav number optimization for swarm. *Reliability engineering & system safety*, Elsevier, v. 223, p. 108478, 2022.
- FRANK, P. M.; ESLAMI, M. Introduction to system sensitivity theory. *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE, v. 10, n. 6, p. 337–338, 1980.
- GERMAN, R. *Performance analysis of communication systems with non-Markovian stochastic Petri nets*. [S.I.]: John Wiley & Sons, Inc., 2000.
- GERMAN, R.; LINDEMANN, C. Analysis of stochastic petri nets by the method of supplementary variables. *Performance evaluation*, Elsevier, v. 20, n. 1-3, p. 317–335, 1994.
- GONCALVES, P.; SOBRAL, J.; FERREIRA, L. A. Unmanned aerial vehicle safety assessment modelling through petri nets. *Reliability Engineering & System Safety*, Elsevier, v. 167, p. 383–393, 2017.
- HAMBY, D. A comparison of sensitivity analysis techniques. *Health physics*, Citeseer, v. 68, n. 2, p. 195–204, 1995.
- HAMBY, D. M. A review of techniques for parameter sensitivity analysis of environmental models. *Environmental monitoring and assessment*, Springer, v. 32, p. 135–154, 1994.
- HAVERKORT, B. R. Markovian models for performance and dependability evaluation. In: *Lectures on Formal Methods and Performance Analysis*. [S.I.]: Springer, 2001.
- JIANG, P.; QI, J. et al. A planning method for operational test of uav swarm based on mission reliability. *CMES-Computer Modeling in Engineering & Sciences*, v. 140, n. 2, 2024.
- KABASHKIN, I. The resilience of electrical support in uav swarms in special missions. *Energies*, MDPI, v. 17, n. 10, p. 2422, 2024.
- KLEINROCK, L. *Theory, Volume 1, Queueing Systems*. USA: Wiley-Interscience, 1975. ISBN 0471491101.
- KUMARI, L.; NANDINI, A.; BHAVITHA, N.; NAIK, S. M.; DAS, M.; MOHAN, B. R. Reliability analysis of petri nets for unmanned aerial vehicles. In: IEEE. *2024 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI)*. [S.I.], 2024. v. 2, p. 1–5.
- LABIB, N. S.; BRUST, M. R.; DANOY, G.; BOUVRY, P. The rise of drones in internet of things: A survey on the evolution, prospects and challenges of unmanned aerial vehicles. *IEEE Access*, IEEE, v. 9, p. 115466–115487, 2021.
- LEE, S.; SONG, Y.; KIL, S.-H. Feasibility analyses of real-time detection of wildlife using uav-derived thermal and rgb images. *Remote Sensing*, MDPI, v. 13, n. 11, p. 2169, 2021.
- LI, J.; LAI, H.; SHI, Y.; YANG, Y.; YANG, F. Uav system reliability test based on random interference optimization. In: IEEE. *2024 5th International Conference on Mobile Computing and Sustainable Informatics (ICMCSI)*. [S.I.], 2024. p. 749–754.

- LIAN, Z.; SU, Y.; WANG, Y.; JIANG, L.; ZHANG, Z.; XIE, Z.; LI, S. A nonstationary 3-d wideband channel model for low-altitude uav-mimo communication systems. *IEEE Internet of Things Journal*, IEEE, v. 9, n. 7, p. 5290–5303, 2021.
- LINDEMANN, C. Performance modelling with deterministic and stochastic petri nets. *ACM sigmetrics performance evaluation review*, Acm New York, NY, USA, v. 26, n. 2, p. 3, 1998.
- LU, M.; BAGHERI, M.; JAMES, A. P.; PHUNG, T. Wireless charging techniques for uavs: A review, reconceptualization, and extension. *IEEE Access*, IEEE, v. 6, p. 29865–29884, 2018.
- MACIEL, P.; MATOS, R.; SILVA, B.; FIGUEIREDO, J.; OLIVEIRA, D.; FÉ, I.; MACIEL, R.; DANTAS, J. Mercury: Performance and dependability evaluation of systems with exponential, expolynomial, and general distributions. In: IEEE. *2017 IEEE 22nd Pacific Rim international symposium on dependable computing (PRDC)*. [S.I.], 2017. p. 50–57.
- MACIEL, P. P. M. *Performance, reliability, and availability evaluation of computational systems*. [S.I.]: Chapman amp; Hall/CRC, 2023. v. 2.
- MACIEL, P. R.; LINS, R. D.; CUNHA, P. R. *Introdução às redes de Petri e aplicações*. [S.I.]: UNICAMP-Instituto de Computacao Sao Paulo, Brazil, 1996.
- MACIEL, P. R. M. *Performance, reliability, and availability evaluation of computational systems*. [S.I.]: Chapman amp; Hall/CRC, 2023. v. 1.
- MACIEL, P. R. M. *Performance, reliability, and availability evaluation of computational systems, Volume 1: Performance and Background*. [S.I.]: CRC Press, 2023.
- MARSAN, M. A.; BALBO, G.; CONTE, G.; DONATELLI, S.; FRANCESCHINIS, G. Modelling with generalized stochastic petri nets. *ACM SIGMETRICS performance evaluation review*, ACM New York, NY, USA, v. 26, n. 2, p. 2, 1998.
- MASMOUDI, N.; JAAFAR, W.; CHERIF, S.; ABDERRAZAK, J. B.; YANIKOMEROGLU, H. Uav-based crowd surveillance in post covid-19 era. *ieee Access*, IEEE, v. 9, p. 162276–162290, 2021.
- MATOS, R.; DANTAS, J.; ARAUJO, E.; MACIEL, P. Bottleneck detection in cloud computing performance and dependability: Sensitivity rankings for hierarchical models. *Journal of Network and Systems Management*, Springer, v. 28, n. 4, p. 1839–1871, 2020.
- MELO, A.; TAVARES, E.; SOUSA, E.; NOGUEIRA, B.; MACIEL, P. A performability approach for evaluating the impact of risks in software development. *International Journal of Software Engineering, Technology and Applications*, Inderscience Publishers (IEL), v. 1, n. 2-4, p. 261–289, 2015.
- MELO, C.; DANTAS, J.; PEREIRA, P.; MACIEL, P. Distributed application provisioning over ethereum-based private and permissioned blockchain: availability modeling, capacity, and costs planning. *The Journal of Supercomputing*, Springer, v. 77, n. 9, p. 9615–9641, 2021.
- MELO, C. A. S. d. *Avaliação da disponibilidade de infraestrutura de sincronização de dados*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2016.
- MEYER. On evaluating the performability of degradable computing systems. *IEEE Transactions on computers*, IEEE, v. 100, n. 8, p. 720–731, 1980.

- MOHSAN, S. A. H.; KHAN, M. A.; NOOR, F.; ULLAH, I.; ALSHARIF, M. H. Towards the unmanned aerial vehicles (uavs): A comprehensive review. *Drones*, MDPI, v. 6, n. 6, p. 147, 2022.
- MOLLOY, M. K. *On the integration of delay and throughput measures in distributed processing models*. [S.I.]: University of California, Los Angeles, 1981.
- MURATA, T. Petri nets: Properties, analysis and applications. *Proceedings of the IEEE*, IEEE, v. 77, n. 4, p. 541–580, 1989.
- NATKIN, S. O. *Les Reseaux de petri stochastiques et leur application de l'évaluation des systemes informatiques*. [S.I.: s.n.], 1980.
- NEWARK, L. R. Drones controlados por SBC para Inspeção Aérea. *Embarcados - Sua fonte de informações sobre Sistemas Embarcados*, jul. 2024. Disponível em: <<https://embarcados.com.br/drones-controlados-por-sbc-para-inspecao-aerea>>.
- NGO, T.-T.; ABDUKHAKIMOV, A.; KIM, D.-S. Long-range wireless tethering selfie camera system using wireless sensor networks. *IEEE Access*, IEEE, v. 7, p. 108742–108749, 2019.
- NYAMUHUNGU, D. The Design and Manufacture of A VTOL UAV. *ResearchGate*, abr. 2022.
- OJHA, S.; SAKHARE, S. Image processing techniques for object tracking in video surveillance-a survey. In: IEEE. *2015 International Conference on Pervasive Computing (ICPC)*. [S.I.], 2015. p. 1–6.
- PUNN, N. S.; SONBHADRA, S. K.; AGARWAL, S.; RAI, G. Monitoring covid-19 social distancing with person detection and tracking via fine-tuned yolo v3 and deepsort techniques. *arXiv preprint arXiv:2005.01385*, 2020.
- SAAD, M. H. M.; HAMDAN, N. M.; SARKER, M. R. State of the art of urban smart vertical farming automation system: Advanced topologies, issues and recommendations. *Electronics*, MDPI, v. 10, n. 12, p. 1422, 2021.
- SABINO, A.; LIMA, L. N.; BRITO, C.; FEITOSA, L.; CAETANO, M. F.; BARRETO, P. S.; SILVA, F. A. Forest fire monitoring system supported by unmanned aerial vehicles and edge computing: a performance evaluation using petri nets. *Cluster Computing*, Springer, p. 1–21, 2024.
- SANDINO, J.; VANEGAS, F.; MAIRE, F.; CACCETTA, P.; SANDERSON, C.; GONZALEZ, F. Uav framework for autonomous onboard navigation and people/object detection in cluttered indoor environments. *Remote Sensing*, MDPI, v. 12, n. 20, p. 3386, 2020.
- SHAKHATREH, H.; SAWALMEH, A. H.; AL-FUQAH, A.; DOU, Z.; ALMAITA, E.; KHALIL, I.; OTHMAN, N. S.; KHREISHAH, A.; GUIZANI, M. Unmanned aerial vehicles (uavs): A survey on civil applications and key research challenges. *Ieee Access*, IEEE, v. 7, p. 48572–48634, 2019.
- SHARMA, V.; JAYAKODY, D. N. K.; YOU, I.; KUMAR, R.; LI, J. Secure and efficient context-aware localization of drones in urban scenarios. *IEEE Communications Magazine*, IEEE, v. 56, n. 4, p. 120–128, 2018.

- SOUSA, E.; MACIEL, P.; ARAUJO, C.; ALVES, G.; CHICOUT, F. Performance modeling for evaluation and planning of electronic funds transfer systems. In: IEEE. *2009 IEEE Symposium on Computers and Communications*. [S.I.], 2009. p. 73–76.
- STEURER, M.; MOROZOV, A.; JANSCHEK, K.; NEITZKE, K.-P. Model-based dependability analysis of fault-tolerant inertial navigation system: A practical experience report. *IFAC-PapersOnLine*, Elsevier, v. 52, n. 12, p. 394–399, 2019.
- STEURER, M.; MUTZKE, T.; MOROZOV, A.; JANSCHEK, K.; NEITZKE, K.-P. Utilizing model-based timing analysis for holistic dependability assessment of unmanned aerial vehicles. In: *30th European Safety and Reliability Conference, ESREL 2020 and 15th Probabilistic Safety Assessment and Management Conference, PSAM 2020*. [S.I.: s.n.], 2020. p. 2065–2072.
- SYMONS, F. J. W. Modelling and analysis of communication protocols using numerical petri nets. 1989.
- TAHIR, A.; BÖLING, J.; HAGHBAYAN, M.-H.; TOIVONEN, H. T.; PLOSILA, J. Swarms of unmanned aerial vehicles—a survey. *Journal of Industrial Information Integration*, Elsevier, v. 16, p. 100106, 2019.
- TRIVEDI, K. S. *Probability & statistics with reliability, queuing and computer science applications*. [S.I.]: John Wiley & Sons, 2008.
- WOLFRAM. *Wolfram: Computation Meets Knowledge*. 2024. [Online; accessed 21. Feb. 2025]. Disponível em: <<https://www.wolfram.com/mathematica>>.
- XING, L.; JOHNSON, B. W. Reliability theory and practice for unmanned aerial vehicles. *IEEE Internet of Things Journal*, IEEE, v. 10, n. 4, p. 3548–3566, 2022.
- YANG, D.; YURTSEVER, E.; RENGANATHAN, V.; REDMILL, K. A.; ÖZGÜNER, Ü. A vision-based social distancing and critical density detection system for covid-19. *Sensors*, MDPI, v. 21, n. 13, p. 4608, 2021.
- ZHANG, L.; CELIK, A.; DANG, S.; SHIHADA, B. Energy-efficient trajectory optimization for uav-assisted iot networks. *IEEE Transactions on Mobile Computing*, IEEE, v. 21, n. 12, p. 4323–4337, 2021.
- ZHAO, P.; WANG, M. Performance analysis of multiple unmanned aerial vehicle collaborative systems based on stochastic petri net. In: IEEE. *2019 11th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*. [S.I.], 2019. v. 1, p. 178–183.

APÊNDICE A – CÓDIGOS-FONTE DE DESENVOLVIMENTO

Código Fonte 1 – Código-fonte Extração da Fórmula Fechada CTMC

```

1 Clear[\[Lambda]d];
2 Clear[\[Lambda]bd];
3 Clear[\[Lambda]bc];
4 Clear[\[Mu]d];
5 Clear[\[Delta]];
6 Clear[\[Beta]];
7 Clear[\[Beta]2];
8 Clear[\[Beta]3];
9 Clear[\[Beta]4];
10 Clear[\[Beta]5];
11 Clear[\[Alpha]1];
12 Clear[\[Alpha]2];
13 Clear[\[Alpha]3];
14 Clear[\[Alpha]4];
15 Clear[\[Phi]1];
16 Clear[\[Phi]2];
17 Clear[\[Phi]3];
18 Clear[\[Phi]4];
19 Clear[\[Phi]5];
20 Clear[\[Theta]1];
21 Clear[\[Theta]2];
22 ClearAll;
23 Mtemp = {{, \[Lambda]d, 0, 0, 0, 0, \[Lambda]bd, 0, 0,
24     0}, {0, , \[Delta], 0, \[Mu]d, 0, 0, 0, 0, 0}, {\[Mu]d,
25     0, , \[Lambda]d, 0, \[Lambda]bd, 0, 0, 0, 0}, {0, 0, \[Mu]d, , 0,
26     0, 0, 0, 0, 0}, {\[Delta], 0, 0, 0, , 0, 0, 0, 0,
27     0}, {0, \[Lambda]bc, 0, 0, 0, , 0, \[Mu]d, 0, 0}, {0, 0, 0, 0, 0, 0,
28     0, , \[Delta], 0, 0}, {\[Lambda]bc, 0, 0, 0, 0, 0,
29     0, , \[Lambda]d, \[Lambda]bd}, {0, \[Lambda]bc, 0, 0, 0, 0,
30     0, \[Mu]d, , 0}, {0, 0, 0, 0, 0, \[Lambda]bc, 0, 0, }};
31 Labels = {"S0", "S1", "S2", "S3", "S4", "S5", "S6", "S7", "S8", "S9"};
32 WorkingQ = {True, False, True, False, False, False, False, True,
33     False, False};
34 (Mx = SetDiagonal[Transpose[Mtemp]]) // MatrixForm;
35 Q = Transpose[Mx] // MatrixForm
36 PlotDiagram[Mx, WorkingQ, Labels]
37 Ps = ProbStationary[Mx] // Simplify;
38 Availability = 1 - UnAvailability[Ps, WorkingQ];
39 Z = FullSimplify[Availability];
40 \[Beta] = \[Lambda]bd + \[Lambda]d;
41 \[Beta]2 = \[Lambda]bd + \[Mu]d;
42 \[Beta]3 = \[Lambda]d + \[Mu]d;
43 \[Beta]4 = \[Lambda]bc + \[Lambda]bd

```

```

\[Beta]5 = \[Lambda]bc + \[Mu]d
45 \[Alpha]1 = \[Beta] + \[Lambda]bc
\[Alpha]2 = \[Beta] + \[Beta]5
47 \[Alpha]3 = \[Beta]3 + \[Beta]4;
\[Alpha]4 = \[Beta]3 \[Lambda]bc + \[Lambda]bd \[Mu]d;
49 \[Phi]1 = \[Alpha]1 \[Lambda]bc + \[Beta]4 \[Mu]d
\[Phi]2 = \[Beta]3 \[Lambda]bc + \[Lambda]bd \[Mu]d;
51 \[Phi]3 = \[Beta] \[Lambda]bc^2 + \[Lambda]bd (2 \[Delta] \[Lambda]bc \
+ (\[Delta] + \[Lambda]bc) \[Lambda]bd);
53 \[Phi]4 = \[Beta]3^2 + \[Beta]3 (\[Lambda]bc +
3 \[Lambda]bd) + \[Lambda]bd (2 \[Lambda]bc + 3 \[Lambda]bd);
55 \[Phi]5 = \[Lambda]d^2 + \[Lambda]d \[Mu]d + \[Mu]d^2;
\[Theta]1 = \[Alpha]1 \[Beta] \[Beta]2 \[Lambda]bc +
57 2 \[Beta] \[Beta]2 \[Delta] \[Lambda]bd + \[Delta] \[Lambda]bc (\ \
\[Phi]4);
59 \[Theta]2 = \[Alpha]4 \[Lambda]bd \[Mu]d + \[Lambda]bc^2 \[Phi]5
P = (\[Delta] \[Lambda]bc \[Mu]d (\[Mu]d (\[Lambda]bd + \[Mu]d) (\ \
61 \[Lambda]bc (\[Lambda]bc + \[Beta]) + (\[Lambda]bc + \[Lambda]bd) \
\ [Mu]d) + \[Delta] (\[Lambda]bc + \[Beta] + \[Mu]d) (\[Lambda]bd \
63 \[Mu]d + \[Lambda]bc (\[Lambda]d + \[Mu]d)))/(\[Lambda]bc \[Mu]d^2 (\ \
\ [Lambda]bd + \[Mu]d) (\[Lambda]bc^2 (\[Beta]) + \[Lambda]bd^2 \[Mu]d \
65 + \[Lambda]bc (\[Beta]) (\[Beta] + \[Mu]d) + \[Delta]^2 (\[Lambda]bc \
+ \[Beta] + \[Mu]d) (\[Lambda]bd^2 \[Mu]d^2 + \[Lambda]bc \[Lambda]bd \
67 \[Mu]d (\[Lambda]d + \[Mu]d) + \[Lambda]bc^2 (\[Lambda]d^2 + \
\ [Lambda]d \[Mu]d + \[Mu]d^2) + \[Delta] \[Mu]d (\[Lambda]bd^2 \
69 \[Mu]d^2 (\[Lambda]bd + \[Mu]d) + \[Lambda]bc \[Lambda]bd \[Mu]d (2 \
\ [Lambda]bd + \[Mu]d) (\[Beta] + \[Mu]d) + \[Lambda]bc^3 (\[Mu]d (\ \
71 \[Lambda]d + \[Mu]d) + \[Lambda]bd (\[Lambda]d + \
2 \[Mu]d)) + \[Lambda]bc^2 (\[Mu]d (\[Lambda]d + \
73 \[Mu]d)^2 + \[Lambda]bd^2 (\[Lambda]d + \
3 \[Mu]d) + \[Lambda]bd (\[Lambda]d + \[Mu]d) \
75 (\[Lambda]d + 3 \[Mu]d)));
77 P2 = (\[Delta] \[Lambda]bc \[Mu]d (\[Beta]2 \[Mu]d \[Phi]1 + \
\[Alpha]2 \[Delta] \[Phi]2))/(\[Alpha]2 \[Delta]^2 \[Theta]2 + \
79 \[Lambda]bc \[Mu]d (\[Alpha]3 \[Delta] \[Lambda]bc \[Lambda]bd \
\ [Lambda]d + \[Theta]1 \[Mu]d) + \[Beta]2 \[Mu]d^3 \[Phi]3);
81 FullSimplify[P2]
FullSimplify[Availability] // TeXForm;

```

Fonte: Elaborado Pelo Autor (2024)

Código Fonte 2 – Código-fonte Validação do Modelo de Cobertura

```

f1 = 4.89;
2 csh = 3.816;
csw = 6.780;
4 oreal = 1.70;

```

```

oimg = 31;
6 rh = 1080;
ah = 124;
8 aw = 130;
dspeed = 3;
10
FVA[f1_, cs_] := 2*ArcTan[cs/(2*f1)];
12 NFVAh = FVA[f1, csh];
NFVAw = FVA[f1, csw];
14
Hmax[oreal_, oimg_, rh_, FVA_] := (oreal*rh)/(2*Tan[FVA]*oimg);
16 Print["Angula o Fov vertical : ", N[NFVAh]];
Print["Angula o Fov horizontal : ", N[NFVAw]];
18 NHmax = Hmax[oreal, oimg, rh, NFVAh];

20 FV[Hmax_, FVA_] := 2*Hmax*Tan[FVA/2];
NFVh = FV[NHmax, NFVAh];
22 NFVw = FV[NHmax, NFVAw];

24 Ni[A_, FV_] := A/FV;
Nc = Ni[aw, NFVw];
26 Nl = Ni[ah, NFVh];

28 CoVlen[Nln_, Ncol_, FVh_, FVw_] :=
  Nln*((Ncol - 1)*FVw) + ((Nln - 1)*FVh);
30
NCovlen = CoVlen[Nl, Nc, NFVh, NFVw];
32
CoVtime[dspeed_, CoVlen_] := CoVlen/dspeed;
34
NCoVtime = CoVtime[dspeed, NCovlen];
36
Print["Altura Max: ", N[NHmax], " m"];
38 Print["Número de colunas: ", N[Nc]]
Print["Número de linhas: ", N[Nl]];
40 Print["Fov Vertical: ", N[NFVh], " m"];
Print["Fov Horizontal: ", N[NFVw], " m"];
42 Print["Distância Percorrida: ", N[NCoVlen], " m"];
Print["Tempo Gasto: ", N[NCoVtime], " s"];

```

Fonte: Elaborado Pelo Autor (2024)

APÊNDICE B – SCRIPTS DE DESENVOLVIMENTO

Código Fonte 3 – Script Mercury Modelo de Disponibilidade

```

1 DN = 20;
2 BN = 0;
3 mttbc = 2;
4 mttdf = 5034;
5 mttdr = 2;
6 mttdb = 0.5;
7 mttds = 0.016666667;

9
SPN Model{
11
    place BC;
13    place BR;
14    place DF;
15    place DR( tokens= DN );
16    place DU( tokens= 1 );
17

19    timedTransition BCG(
20        inputs = [BC],
21        outputs = [BR],
22        delay = mttbc,
23        serverType = "InfiniteServer"
24    );
25
26    timedTransition BD(
27        inputs = [DU],
28        outputs = [BC, DR],
29        delay = mttdb
30    );
31
32    timedTransition DFF(
33        inputs = [DU],
34        outputs = [DF],
35        delay = mttdf
36    );
37
38    timedTransition DR2(
39        inputs = [DF],
40        outputs = [DR, BR],
41        delay = mttdr,
42        guardExpression = #DU>0
43    );

```

```

45     timedTransition DRR(
46         inputs = [DF],
47         outputs = [DU],
48         inhibitors = [DU],
49         delay = mttdr
50     );
51
52     timedTransition DSW(
53         inputs = [DR, BR],
54         outputs = [DU],
55         inhibitors = [DU],
56         delay = mttds,
57         serverType = "InfiniteServer"
58     );
59
60     metric A = stationaryAnalysis( method = "direct", expression = "P{#DU>0}" );
61     metric DTyd = stationaryAnalysis( method = "direct", expression = "((1-(P{#DU
62         >0}))*8760)/24" );
63 }
64
65 main {
66     setIntegerParameters("DN", "BN");
67
68     A = solve( Model,A );
69     println(A);
70
71     DTyd = solve( Model,DTyd );
72     println(DTyd);
73 }
```

Fonte: Elaborado Pelo Autor (2024)

Código Fonte 4 – Script Mercury Modelo de Confiabilidade

```

1 DN = 1;
2 BN = 0;
3 mttdc = 2;
4 mttdf = 5034;
5 mttdr = 2;
6 mttdb = 3;
7 mttds = 0.016666667;
8 y = 10;
9 TTF = 0.005;

11
SPN Model{
```

```
13     place BC;
15     place BR;
16     place DF;
17     place DR( tokens= 1 );
18     place DU( tokens= 1 );
19     place P1;
20     place P2;
21     place P3;
22     place P4;
23     place P5;

25
26     immediateTransition TI2(
27         priority = 2,
28         inputs = [DF, P2, DR("#DR")],
29         outputs = [P3]
30     );
31
32     immediateTransition TI3(
33         inputs = [P1],
34         outputs = [P1, P4(y)],
35         inhibitors = [P5, P4]
36     );
37
38     immediateTransition TI4(
39         inputs = [P1, P5(y)],
40         outputs = [P2]
41     );
42
43     immediateTransition TI5(
44         priority = 2,
45         enablingFunction = "#DU>0",
46         inputs = [P1]
47     );
48
49     immediateTransition TI6(
50         enablingFunction = "(#DU>0)AND(#P4>0)",
51         inputs = [P4("#P4")]
52     );
53
54     immediateTransition TI7(
55         enablingFunction = "(#DU>0)AND(#P5>0)",
56         inputs = [P5("#P5")]
57     );
58
59     immediateTransition TI8(
```

```
           inputs = [DR("#DR"), P2],
61         outputs = [P3]
      );
63
      timedTransition BCG(
65       inputs = [BC],
66       outputs = [BR],
67       delay = mttbc,
68       serverType = "InfiniteServer",
69       guardExpression = #P3==0
70     );
71
      timedTransition BD(
73       inputs = [DU],
74       outputs = [BC, DR, P1],
75       delay = mttbd
76     );
77
      timedTransition DFF(
79       inputs = [DU],
80       outputs = [DF, P1],
81       delay = mttdf
82     );
83
      timedTransition DR2(
85       inputs = [DF],
86       outputs = [DR, BR],
87       delay = mttdr,
88       guardExpression = #DU>0
89     );
90
91      timedTransition DRR(
92       inputs = [DF],
93       outputs = [DU],
94       inhibitors = [DU],
95       delay = mttdr,
96       guardExpression = (#DR>0)AND(#BR>0)
97     );
98
99      timedTransition DSW(
100       inputs = [DR, BR],
101       outputs = [DU],
102       inhibitors = [DU],
103       delay = mttds,
104       serverType = "InfiniteServer",
105       guardExpression = #P3==0
106     );
107
```

```

107     timedTransition TE3(
108         inputs = [P4],
109         outputs = [P5],
110         delay = TTF
111     );
113
114     metric R = stationaryAnalysis( method = "direct", expression = "P{#P3=0}" );
115 }
116
117 main {
118     setIntegerParameters("DN", "BN", "y");
119
120     R = solve( Model,R );
121     println(R);
122
123 }
```

Fonte: Elaborado Pelo Autor (2024)

Código Fonte 5 – Script Mercury Modelo de Performabilidade

```

1 DN = 0;
2 BN = 6;
3 mttbc = 2;
4 mttdf = 5034;
5 mttdr = 2;
6 mttdb = 0.5;
7 mttds = 0.016666667;
8 GOINGTIME = 0.048212614;
9 BACKTIME = 0.048212614;
10 y = 4;
11
12
13 SPN Model{
14
15     place BC( tokens= 0 );
16     place BR( tokens= BN );
17     place DF;
18     place DR;
19     place DU( tokens= 1 );
20     place END;
21     place GUARD;
22     place P0( tokens= y );
23     place P1;
24     place P2;
25     place P3;
26     place START( tokens= 1 );
```

```
27
29     immediateTransition TI12(
30         enablingFunction = "((#P0>0)OR(#P2>0))AND(#DU=0)" ,
31         inputs = [P0("#P0"), P2("#P2")]
32     );
33
34     immediateTransition TI13(
35         enablingFunction = "((#P1>0)OR(#P3>0))AND(#DU=0)" ,
36         inputs = [P1("#P1"), P3("#P3")]
37     );
38
39     immediateTransition TI3(
40         priority = 2,
41         inputs = [START],
42         outputs = [GUARD],
43         inhibitors = [DU]
44     );
45
46     immediateTransition TI4(
47         inputs = [DU, GUARD],
48         outputs = [DU, START]
49     );
50
51     immediateTransition TI5(
52         priority = 2,
53         inputs = [END],
54         outputs = [GUARD],
55         inhibitors = [DU]
56     );
57
58     immediateTransition TI6(
59         inputs = [START],
60         outputs = [START, P0(y)],
61         inhibitors = [P1, P0]
62     );
63
64     immediateTransition TI7(
65         inputs = [P1(y), START],
66         outputs = [END]
67     );
68
69     immediateTransition TI8(
70         inputs = [P2(y), END],
71         outputs = [START]
72     );
73
```

```
immediateTransition TI9(
    inputs = [END],
    outputs = [P3(y), END],
    inhibitors = [P2, P3]
);

timedTransition BCG(
    inputs = [BC],
    outputs = [BR],
    delay = mttbc,
    serverType = "InfiniteServer"
);

timedTransition BD(
    inputs = [DU],
    outputs = [BC, DR],
    delay = mttbd
);

timedTransition DFF(
    inputs = [DU],
    outputs = [DF],
    delay = mttdf
);

timedTransition DR2(
    inputs = [DF],
    outputs = [DR, BR],
    delay = mttdr
);

timedTransition DRR(
    inputs = [DF],
    outputs = [DU],
    inhibitors = [DU],
    delay = mttdr
);

timedTransition DSW(
    inputs = [DR, BR],
    outputs = [DU],
    inhibitors = [DU],
    delay = mttds,
    serverType = "InfiniteServer"
);

timedTransition TE0(
```

```

121         inputs = [P0],
122         outputs = [P1],
123         delay = BACKTIME
124     );
125
126     timedTransition TE1(
127         inputs = [P3],
128         outputs = [P2],
129         delay = GOINGTIME
130     );
131
132     metric A = stationaryAnalysis( method = "direct", expression = "P{#DU>0}" );
133     metric DTyd = stationaryAnalysis( method = "direct", expression = "((1-(P{#DU
134         >0}))*8760)/24" );
135     metric TPrph = stationaryAnalysis( method = "direct", expression = "((P{#
136         START>0}*(1/GOINGTIME))+(P{#END>0}*(1/BACkTIME)))" );
137     metric PDWB = stationaryAnalysis( method = "direct", expression = "P{(#DU=0)
138         AND(#BR=0)AND(#DR>0)}" );
139     metric AVGDA = stationaryAnalysis( method = "direct", expression = "E{#DR}" )
140         ;
141     metric AVGBA = stationaryAnalysis( method = "direct", expression = "E{#BR}" )
142         ;
143     metric TPrpm = stationaryAnalysis( method = "direct", expression = "((P{#
144         START>0})*(1/GOINGTIME))+(P{#END>0}*(1/BACkTIME)))/(60)" );
145 }
146
147 main {
148     setIntegerParameters("DN", "BN", "y");
149
150     A = solve( Model,A );
151     println(A);
152
153     DTyd = solve( Model,DTyd );
154     println(DTyd);
155
156     TPrph = solve( Model,TPrph );
157     println(TPrph);
158
159     PDWB = solve( Model,PDWB );
160     println(PDWB);
161
162     AVGDA = solve( Model,AVGDA );
163     println(AVGDA);
164
165     AVGBA = solve( Model,AVGBA );
166     println(AVGBA);
167
168 }
```

```
163     TPrpm = solve( Model ,TPrpm );
        println(TPrpm);
165 }
```

Fonte: Elaborado Pelo Autor (2024)