

# Entregas Aéreas por Drones: Uma Avaliação de Desempenho Considerando Colisões dos drones e Logística de Reparo

Leonel Feitosa<sup>1</sup>, Vандirleya Barbosa<sup>1</sup>, Luiz Fernando Bittencourt<sup>2</sup>,  
Fabiola M. C. de Oliveira<sup>3</sup>, José Valdemir R. Junior<sup>1</sup> e Francisco Airton Silva<sup>1</sup>

<sup>1</sup>Universidade Federal do Piauí – PI – Brasil

<sup>2</sup>Universidade de Campinas – SP – Brasil

<sup>3</sup>Universidade Federal do ABC – SP – Brasil

{leonelfeitosa,vandirleya.barbosa,valdemirreis,faps}@ufpi.edu.br

bit@ic.unicamp.br, fabiola.oliveira@ufabc.edu.br

**Resumo.** A crescente adoção de drones para entrega de mercadorias tem se apresentado como uma solução potencialmente viável. Ao operarem pelo ar, os drones reduzem o tempo de entrega e ampliam o alcance das operações. No entanto, para cobrir grandes áreas, drones em voos prolongados consomem muita bateria, e o risco de colisões aumenta significativamente em regiões densamente povoadas. Este estudo propõe um modelo baseado em Redes de Petri Estocásticas para avaliar o desempenho de drones, considerando métricas como utilização, taxa de entregas e tempo médio de missão. O modelo considera fatores como pontos estratégicos de recarga e a probabilidade de colisão, fornecendo previsões sobre o desempenho dos drones em cenários de alta demanda. Além disso, foi realizada uma análise de sensibilidade utilizando o Design de Experimentos para identificar os fatores mais influentes no desempenho dos drones, possibilitando uma melhor compreensão e otimização do sistema.

**Abstract.** The growing adoption of drones for goods delivery has emerged as a potentially viable solution. By operating through aerial routes, drones significantly reduce delivery times and expand the operational reach. However, covering large areas requires prolonged flights, leading to high battery consumption and an increased risk of collisions, particularly in densely populated regions. This study presents a Stochastic Petri Net model to evaluate drone performance, focusing on metrics such as utilization, delivery rate, and mean mission time. The model incorporates factors such as strategic recharging points and collision probability, providing insights into drone performance under high-demand scenarios. Additionally, a sensitivity analysis was conducted using the Design of Experiments to identify the most influential factors impacting drone performance, enabling a deeper understanding and optimization of the system.

## 1. Introdução

Nos últimos anos, a adoção de drones para entregas revolucionou o setor logístico, oferecendo soluções para o transporte de mercadorias em contextos comerciais e hospitalares. Em 2023, o mercado global de entregas por drones foi avaliado em US\$ 1,68

bilhão, com previsão de crescimento para US\$ 4,35 bilhões até 2027, impulsionado principalmente pela região da Ásia-Pacífico (39%), seguida pela América do Norte e Europa [Statista Research Department 2024]. Além de otimizar rotas e tempos de entrega, os drones cooperativos ampliam a capacidade operacional, permitindo maior eficiência na distribuição de pacotes e na gestão de volumes elevados [Behroozi and Ma 2023]. Em setores comerciais e hospitalares, o transporte de mercadorias por drones tem mostrado potencial para atender demandas em áreas de difícil acesso [Hicks 1959]. Modelos de simulação, como Redes de Petri Estocásticas (SPNs), são empregados para prever o desempenho desses sistemas, considerando fatores como taxa de entrega, utilização dos drones e tempo médio de missão [Silva et al. 2024]. Essas ferramentas permitem não apenas otimizar a alocação de recursos, mas também identificar gargalos operacionais, especialmente em regiões densamente povoadas, onde a demanda é elevada.

Apesar de promissores, os drones de entrega podem ter custos elevados, variando de alguns milhares de dólares a até US\$ 60 mil, dependendo de características como tamanho, capacidade de carga [JOUAV 2024]. Utilizando sensores aliados a redes neurais, esses drones são capazes de evitar obstáculos com baixo consumo de recursos, além de navegar autonomamente em ambientes com alta densidade de obstáculos, esquinas e becos sem saída, sem ficarem presos ou colidirem [Devos et al. 2018]. Ao considerar a utilização de um conjunto de drones para atender demandas específicas de entrega, torna-se necessário aplicar métodos que possibilitem avaliar seu desempenho para planejamento de capacidade antes da aquisição, garantindo decisões mais informadas.

A crescente adoção de drones para entregas está transformando a logística moderna, proporcionando benefícios como redução de custos, maior agilidade no transporte e acesso a áreas de difícil alcance. No entanto, essas operações enfrentam desafios, especialmente em ambientes urbanos densos, onde a presença de obstáculos móveis e fixos aumenta o risco de colisões dos drones. Essas colisões são frequentemente provocadas por fatores como a variedade de obstáculos, condições ambientais imprevisíveis e interações complexas entre dispositivos aéreos. Apesar de as atuais aplicações reduzirem e avaliarem o impacto das colisões, estas ainda carecem de avanço. Assim, as SPNs podem ser utilizadas para modelar e prever probabilisticamente o desempenho de drones, analisando a capacidade de atender demandas. SPNs são conhecidas pelo alto grau de representatividade, sendo mais intuitivas que opções convencionais, como cadeias de Markov, para representar concorrência, paralelismo e sincronização em sistemas [Silva et al. 2023]. Alguns trabalhos utilizam modelos analíticos relacionados ao problema abordado, porém sem explorar, por exemplo, a chegada contínua de novas demandas de entrega. Visando avaliar o desempenho de seu uso em uma escala mais abrangente e avaliar a probabilidade de colisão dos drones, este trabalho utiliza modelos SPN capazes de antecipar o nível de utilização dos drones cooperativos na entrega contínua de pacotes.

Este trabalho propõe um modelo SPN para avaliar o desempenho de drones em operações de entrega, considerando fatores como tempo de recarga, taxa de chegada de demandas e probabilidade de colisão. O modelo, baseado no cenário descrito na Seção 3, é composto por 23 transições e 19 lugares. Esse cenário, que considera pontos estratégicos de recarga e a dinâmica de colisões em ambientes urbanos, é utilizado como base para a modelagem e avaliação do sistema. Além disso, o modelo incorpora uma análise de sensibilidade utilizando o *Design* de Experimentos (DoE) para identificar os fatores mais

influentes sobre a principal métrica de desempenho, o Tempo Médio de Missão (TMM). A análise permite compreender como variações nos parâmetros impactam o desempenho do sistema.

Na Seção 2, apresentamos os trabalhos relacionados. A Seção 3 descreve o cenário, além do modelo proposto e suas métricas. Na Seção 4, apresentamos dois casos de uso. No primeiro, são apresentados os resultados numéricos, analisando o impacto de variáveis como a taxa de chegada de novas entregas e a probabilidade de colisão. No segundo, realizamos uma análise de sensibilidade usando o DoE. Por fim, a Seção 5 apresenta as conclusões do trabalho e sugestões para pesquisas futuras.

## **2. Trabalhos Relacionados**

A utilização de drones para entrega de mercadorias tem evoluído consideravelmente nos últimos anos, impulsionada por avanços tecnológicos que permitem maior eficiência e segurança nas operações. Estudos têm explorado diferentes aspectos dessas entregas. O estudo de [Du et al. 2022] propõe um modelo para melhorar a distribuição de suprimentos médicos durante emergências de saúde pública, considerando restrições como entrega sem contato e capacidade dos drones, além de realizar análises de sensibilidade para planejamento logístico. O trabalho de [Shi et al. 2022] busca otimizar o roteamento de drones em entregas e coletas simultâneas, avaliando o impacto da velocidade e da bateria na eficiência do sistema. Já [Mateen et al. 2020] analisam o dimensionamento da frota de drones e o tempo de entrega, destacando a redução no tempo de transporte de medicamentos e realizando análises de sensibilidade sobre a permanência nos pontos de entrega. No entanto, essas investigações não consideram explicitamente a probabilidade de colisão entre drones ou a necessidade de recarga, aspectos essenciais para garantir a viabilidade de operações contínuas em larga escala.

Por outro lado, algumas pesquisas têm explorado esses desafios, buscando soluções para aprimorar a segurança e a autonomia das entregas. No contexto da recarga, o estudo de [Dhote and Limbourg 2020] propõe um modelo para projetar redes de transporte de materiais biomédicos, otimizando a alocação da demanda e o uso de estações de recarga, sem exigir grandes reconfigurações. O trabalho de [Namiki 2022] utiliza redes de Petri para simular e avaliar estratégias de entrega, buscando reduzir o tempo e os custos operacionais. O estudo de [Huang et al. 2023] explora métodos de planejamento de voo voltados à extensão da autonomia dos drones por meio de estações de recarga distribuídas. Já [Bhuiyan et al. 2024] analisa a otimização de frotas em entregas diretas de produtos sensíveis ao tempo, considerando a substituição de baterias em diferentes condições operacionais. Em paralelo, outras pesquisas abordam a prevenção de colisões em serviços de entrega aérea. O estudo de [de Oliveira et al. 2024] avalia três abordagens geométricas para mitigar riscos em espaços de tráfego intenso, permitindo que drones ajustem sua trajetória dinamicamente em ambientes urbanos densos. Por fim, o trabalho de [Iqbal and Buhnova 2022] propõe o uso de redes de Petri para que drones monitorem e avaliem o comportamento de outros drones em tempo de execução, detectando desvios e garantindo maior precisão nas operações.

A Tabela 1 resume os trabalhos relacionados, destacando as métricas avaliadas, os métodos utilizados e a consideração de aspectos essenciais, como recarga de baterias, probabilidade de colisão e análise de sensibilidade. Neste contexto, este trabalho

se diferencia ao integrar simultaneamente a logística de entrega, a probabilidade de colisão e a recarga dos drones em um modelo baseado em SPN. Essa modelagem captura interações probabilísticas, permitindo uma análise mais abrangente de cenários operacionais complexos. Outro diferencial é a dinâmica de colisões e reparos, incluindo o tempo de substituição dos drones, um aspecto ausente nos trabalhos analisados. Além disso, a análise de sensibilidade conduzida identifica os fatores mais influentes no desempenho do sistema de entregas, algo pouco explorado na literatura. Assim, este estudo preenche lacunas existentes ao propor uma abordagem integrada que considera eventos estocásticos, restrições operacionais e o impacto de variáveis críticas, fornecendo uma base para a otimização de sistemas logísticos com drones em cenários dinâmicos e de alta variabilidade.

**Tabela 1. Trabalhos relacionados.**

Trabalhos	Métricas	Método de Avaliação	Recarga nos Drones	Probabilidade de Colisão	Análise de Sensibilidade
[Du et al. 2022]	Tempo de viagem, tempo de atendimento	Modelo Matemático	×	×	✓
[Dhote and Limbourg 2020]	Número de viagens, distância percorrida	Modelo Matemático	✓	×	×
[Namiki 2022]	Taxa de operação, tempo de entrega, taxa de utilização de drones, número total de pacotes entregues	Redes de Petri	✓	×	×
[Shi et al. 2022]	Energia, tempo, número de drones	Modelo de Otimização de Rota	×	×	✓
[Iqbal and Buhnova 2022]	Confiabilidade em tempo real	Redes de Petri	×	✓	×
[Mateen et al. 2020]	Tempo de resposta	Experimento	×	×	✓
[de Oliveira et al. 2024]	Taxa de colisão, tempo médio de viagens	Modelo de Cadeias de Markov e Simulação	×	✓	×
[Huang et al. 2023]	Tempo total de viagem, Consumo de energia, Número de Paradas nas Estações de Recarga	Modelo Matemático e Simulação	✓	×	×
[Bhuiyan et al. 2024]	Número de Substituições de Bateria, Número de Drones, Consumo de energia	Modelo Matemático e Simulação	✓	×	✓
Este trabalho	TMM, utilização de drones, taxa de entrega	Rede de Petri Estocástica	✓	✓	✓

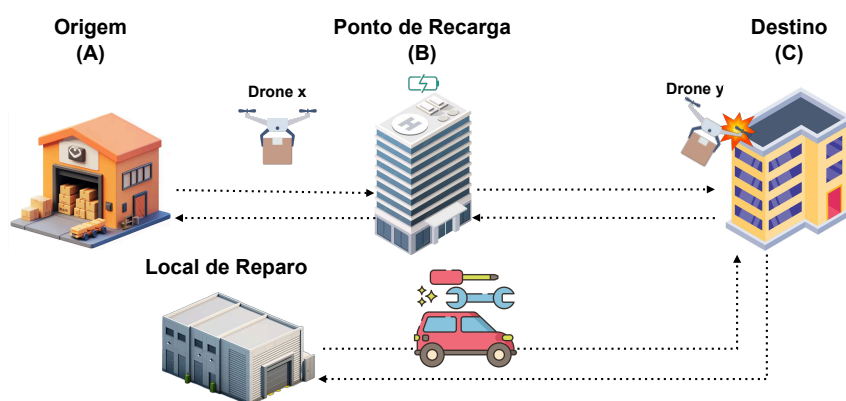
### 3. Modelagem Proposta

Esta seção apresenta o modelo desenvolvido para analisar o desempenho de drones em entregas, descrevendo o cenário base com pontos de recarga, o modelo SPN proposto e as métricas de avaliação.

#### 3.1. Cenário de Entrega por Drones

A Figura 1 apresenta o cenário de entrega de pacotes por drones. Os drones são programados para realizar entregas, saindo da origem (A) — que pode ser um centro de distribuição ou uma base logística localizada estrategicamente — em direção ao destino (C), com uma parada intermediária para recarga (B), inspirado pelo trabalho de

[Dhote and Limbourg 2020]. Este ponto intermediário é selecionado considerando fatores como proximidade em relação à rota principal, capacidade de atender a múltiplos drones simultaneamente e segurança, garantindo uma recarga sem interrupções operacionais. Durante a recarga, os drones são conectados a estações automatizadas que utilizam tecnologias de carregamento dos drones. Após a recarga, os drones retomam sua jornada em direção ao destino (C). Ao chegar ao destino, os drones são recarregados novamente, para estarem prontos para retornar ao centro de distribuição e assim iniciar uma nova missão.



**Figura 1. Visão geral do esquema de transporte de pacotes por drones considerando um ponto de recarga e colisão de drones.**

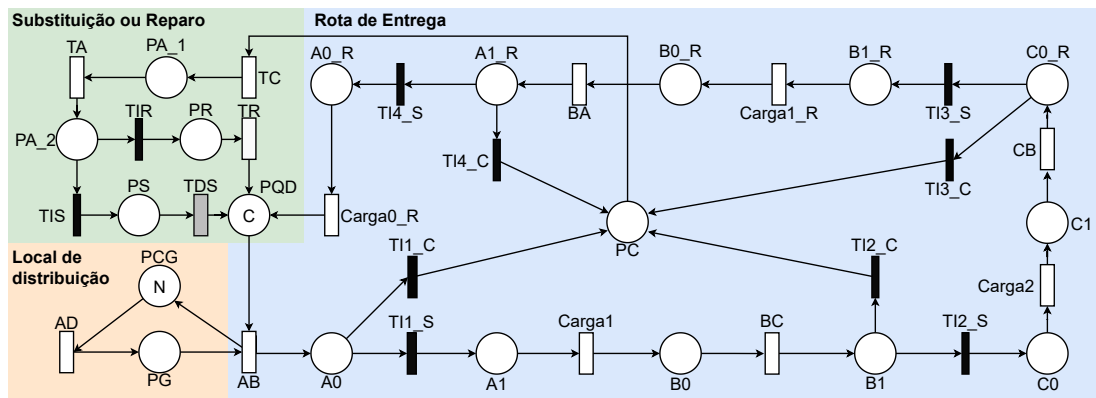
Além de rotas otimizadas e recargas estratégicas, a logística é projetada para lidar com eventualidades, como colisões com objetos. Em situações de colisão, uma equipe de reparo e manutenção é acionada imediatamente para recolher o drone colidido. O reparo envolve a análise detalhada dos danos, que pode incluir a troca de peças, recalibração de sensores ou substituição completa do drone, dependendo da extensão dos problemas identificados. Os drones colididos são levados ao local de análise técnica, onde se decide pela reparação ou descarte, conforme os critérios estabelecidos em [Lord Drone 2024]. A combinação de rotas otimizadas, recargas estratégicas, reparo ou substituição de drone em caso de colisão e eficiência energética resultam em um sistema de entrega rápido e confiável [de Oliveira et al. 2024].

### 3.2. Modelo SPN Proposto

O modelo foi construído e simulado na ferramenta Mercury (versão 5.0.1) [Maciel et al. 2017]. A Figura 2 apresenta o modelo SPN proposto, no qual todas as transições são do tipo *infinite server semantics* [Mahulea et al. 2010], ou seja, podem ser disparados *tokens* simultâneos enquanto a transição em questão esteja habilitada [Girault and Valk 2013]. Os *tokens* representam unidades de recurso ou estados do sistema e são utilizados para descrever a dinâmica do modelo, indicando, por exemplo, o fluxo de pacotes ou drones ao longo das etapas do processo. Esse tipo de modelagem é amplamente empregado para capturar a interação entre componentes em sistemas complexos [Bause and Kritzinger 2002].

A Figura 2 e a respectiva descrição dos componentes na Tabela 2 destacam a estrutura do modelo considerando a arquitetura com pontos de recarga de bateria e probabilidade de colisão. A fase inicial do sistema refere-se à recepção de pacotes no sistema de entrega, no qual AD (*Arrival Delay*) representa o intervalo entre as chegadas dos pacotes para entrega. O lugar PG marca o ponto do percurso onde os pacotes de entrega entram no sistema e, no lugar PQD (marcação C), os drones de entrega aguardam em posição. A ativação da transição AB indica que os drones de entrega receberam os pacotes e estão partindo em uma missão de entrega, iniciando em A1. Os drones recarregam na transição Carga1 antes de atingir o ponto de recarga representado pelo lugar B0, que simboliza a chegada ao destino B apresentado na Figura1. Após alcançar o ponto B0, os drones estão prontos para continuar o trajeto no lugar B1, partindo de B para C na transição BC, até atingirem o destino C no lugar C0. Ao chegar em C0, a transição Carga2 é acionada para iniciar o recarregamento, preparando-se no local C1 para a jornada de retorno. Para iniciar o trajeto de volta, a transição CB\_R encaminha os drones da origem C para o destino B. No lugar B1\_R, os drones alcançam o destino B e realizam a recarga da bateria na transição Carga1\_R. Quando a bateria está carregada, eles se preparam no lugar B0\_R para iniciar o trajeto de retorno, saindo da origem B para o destino A, conforme indicado pela transição BA. A chegada ao destino A (lugar A0\_R) é marcada pela transição Carga0, onde ocorre a recarga, e os drones aguardam em posição no lugar PQD para iniciar uma nova missão.

Durante o processo da missão, podem ocorrer colisões com obstáculos fixos. A probabilidade de uma colisão acontecer está nas transições imediatas TI1\_C, TI2\_C, TI3\_C, TI4\_C. Caso uma colisão aconteça, o *token* seguirá até o lugar PC; caso contrário, seguirá pelas transições imediatas TI1\_S, TI2\_S, TI3\_S, TI4\_S. A transição TC representa o tempo associado à equipe de suporte para localizar o drone colidido e retornar ao local de avaliação, que é alcançado quando o *token* chega ao lugar PA\_1. O início da análise é marcado pela transição TA, na qual, posteriormente, o *token* (drone) pode seguir por TIR, caso seja possível o reparo, ou por TIS, caso o drone necessite ser substituído por um novo. Se o *token* seguir por TIR, ele chegará ao local de reparo no lugar PR e, em seguida, passará pela transição TR até ser reposto na frota em PQD. Caso o *token* siga por TIS, o drone chegará ao lugar PS e aguardará um tempo determinístico associado a TDS para que sua substituição seja realizada. Por fim, será reposto na frota de drones no lugar PQD.



**Figura 2. Modelo SPN para avaliar logística de entregas por drones.**

**Tabela 2. Descrição dos principais componentes do modelo SPN proposto.**

Tipo	Componente	Descrição
Lugares	A0, A1, B0, B1, C0, C1	Pontos do trajeto considerando a ida.
	A0_R, A1_R, B0_R, B1_R, C0_R	Pontos do trajeto considerando o retorno.
	PQD	Local associado à quantidade de drones disponíveis para a operação.
	PC	Local onde o drone se encontra após colisão.
	PA_1, PA_2	Local onde se realiza a análise do grau de danos no drone após colisão.
	PS	Local para substituição de drone.
	PR	Local para reparo do drone.
Transição Temporizada	Carga1, Carga1_R, Carga2	Tempos de recarregar a bateria do drone.
	AB, BC, CB, BA	Tempos referentes à transição de um ponto a outro.
	TC	Tempo referente à coleta do drone no local da colisão.
	TA	Tempo para análise do funcionamento do drone colidido.
	TR	Tempo para reparar o drone após colisão.
Transição Imediata	TI1_S, TI2_S, TI3_S, TI4_S	Probabilidade do drone seguir a operação sem colisão.
	TI1_C, TI2_C, TI3_C, TI4_C	Probabilidade do drone colidir.
	TIR	Probabilidade do drone ser reparado.
	TIS	Probabilidade do drone ser substituído.
Transição Determinística	TDS	Tempo para substituir o drone colidido.
Marcadores de Lugares	C	Quantidade de drones disponíveis para missão.
	N	Quantidade de pacotes a serem entregues.
	AD	Intervalo entre as chegadas dos pacotes para entrega.

A estrutura do modelo proposto permite analisar o comportamento do sistema de entregas considerando fatores como recarga e colisões. A partir dessa modelagem, podem ser obtidas métricas que descrevem o funcionamento do sistema, como o tempo médio de missão, a utilização dos drones e a taxa de entrega. Essas métricas auxiliam na compreensão do impacto de diferentes variáveis no processo de entrega.

O tempo médio de resposta (*MRT*) pode ser obtido a partir da Lei de Little [Jain 1990]. A lei indica que o *MRT* é dado pela multiplicação da quantidade de requisições dentro do sistema pelo tempo entre chegadas (*AD*). No modelo, o tempo entre chegadas reside na transição de nome *AD*, localizada na extremidade esquerda do modelo. Neste artigo, as requisições são os drones, e chamamos o *MRT* de *TMM*. Assim, o número de elementos no sistema é a soma dos *tokens* em todos os lugares por onde passam os drones. Por ter um único lugar de capacidade (*PQD*) no modelo apresentado, esta soma pode ser facilmente obtida por  $C - Esp\{PQD\}$ , em que *C* é a quantidade total de drones e  $Esp\{PQD\}$  representa o número de *tokens* no lugar *PQD* naquele momento.  $Esp\{NomeDoLugar\}$  representa a esperança estatística de existirem *tokens* em “NomeDoLugar”, em que  $Esp\{NomeDoLugar\} = (\sum_{i=1}^n P(m(Local) = i) \times i)$ , sendo *n* o maior número de *tokens* que o *Local* pode conter. Em outras palavras,  $Esp\{NomeDoLugar\}$  indica o valor esperado de *tokens* naquele local em determinado momento ou estacionariamente. Portanto, a equação correspondente à Lei de Little para *TMM* utilizada no nosso modelo é expressa na Equação 1:

$$TMM = (C - Esp\{PQD\}) \times AD. \quad (1)$$

A utilização dos drones é a divisão do número esperado de *tokens* em um local por onde passam os *tokens* executados pela respectiva capacidade total. A utilização média do processamento é dada pela Equação 2, lembrando-se que  $C - Esp\{PQD\}$  retorna para este modelo o número de elementos dentro do sistema:

$$U = \frac{C - Esp\{PQD\}}{C}. \quad (2)$$

A Taxa de Entrega (TE) é dada pela soma da vazão. O cálculo da vazão de um par (lugar,transição) é dado pela divisão do número de *tokens* naquele lugar ( $Esp\{lugar\}$ ) pelo tempo daquela transição ( $T\{transicao\}$ ). Assim, TE é dada pela equação 3:

$$TE = \frac{Esp\{B0\}}{T\{BC\}}. \quad (3)$$

## 4. Estudos de Caso

Esta seção apresenta dois estudos de caso para avaliar o modelo proposto. O primeiro analisa o impacto da taxa de chegada e da probabilidade de colisão no desempenho das entregas. O segundo aplica uma análise de sensibilidade para identificar os fatores mais influentes no tempo médio de missão

### 4.1. Estudo de Caso 1: Desempenho de Entregas por Drones

Nesta seção é apresentado o estudo de caso que utiliza-se o modelo proposto. Para os parâmetros do modelo, utilizamos inicialmente os valores mostrados na Tabela 3 para os tempos das transições, tais tempos médios foram baseados no artigo de [Namiki 2022] e empresas que prestam serviço de reparo em drones [Lord Drone 2024, Frizo Drone 2024]. Nos estudos de caso a seguir varia-se a taxa de chegada de 1 até 500 pacotes por hora para as Figura 3a,b,c. Para o Peso de Colisão na Figura 3d, foi fixado o AD em 0,5 h e N como a quantidade de pacotes a serem entregues em 750.

Vale ressaltar que esses parâmetros são configuráveis e podem ser diferentes para cada realidade a depender do tipo de drone, distâncias, entre outros parâmetros.

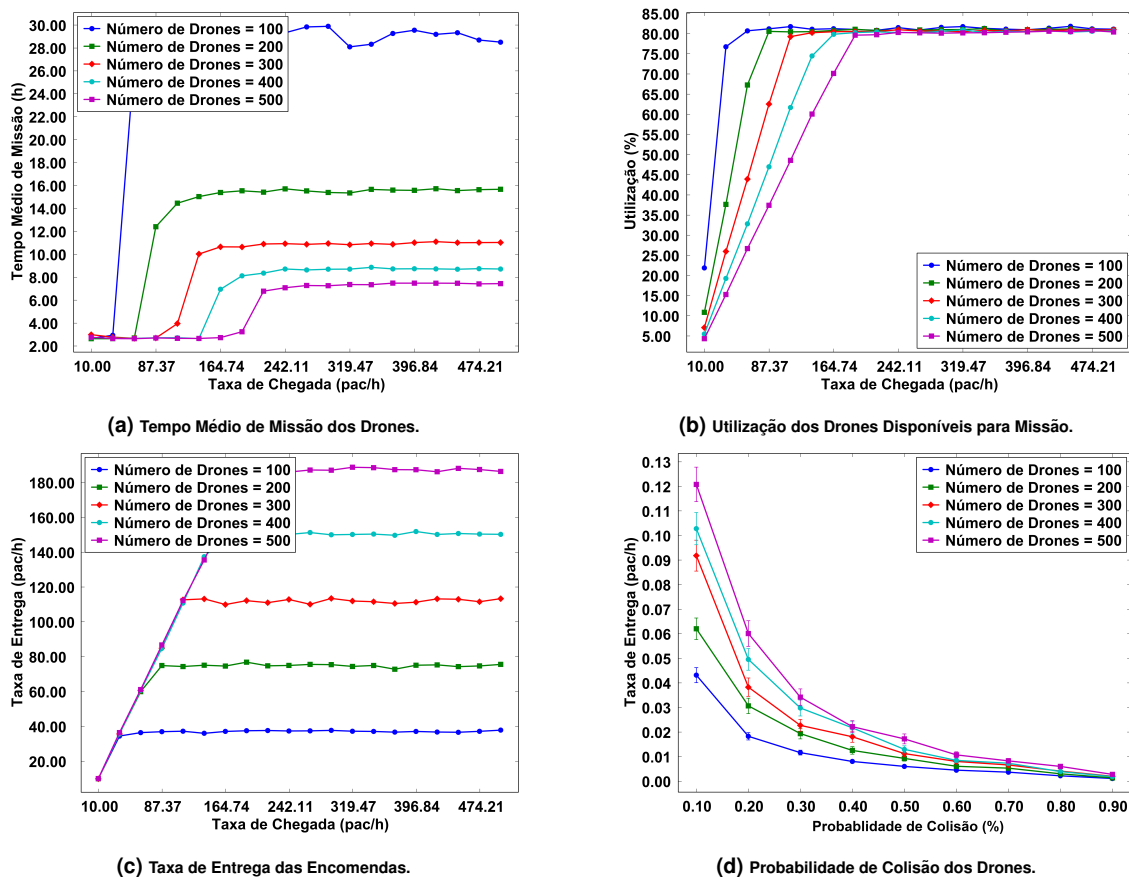
**Tabela 3. Parâmetros utilizados para alimentar o modelo.**

Componentes	Valor (h)
Tempo de transporte	0,5
Tempo de recarga da bateria	0,16
Tempo de repasse de um ponto a outro	0,03
Tempo de coleta do drone no local da colisão	8,0
Tempo de análise do drone	48,0
Tempo de reparo do drone	120,0
Tempo de substituição do drone	0,5

A Figura 3 apresenta os resultados da análise do impacto da variação no número de drones (100, 200, 300, 400 e 500) sobre diferentes métricas de desempenho, considerando como variáveis a taxa de chegada e a probabilidade de colisão. Esses valores foram embasados na abordagem utilizada por [Rahman et al. 2021], que demonstraram



a viabilidade e a aplicabilidade de diferentes capacidades de drones em um sistema de entrega baseado em *blockchain*. Cada gráfico detalha aspectos das operações, levando em consideração cenários variados.



**Figura 3. Resultados de desempenho do sistema de entrega por drones.**

A Figura 3a mostra o tempo médio da missão em função da taxa de chegada. A distância das linhas mostra que, para 100 drones, o tempo médio ultrapassa 27 horas em taxas superiores a 87 pacotes por hora, enquanto para 500 drones permanece constante em cerca de 2,7 horas, mesmo em taxas altas. O ângulo de crescimento é alto para 100 drones, destacando limitações na capacidade de processamento. Um ponto notável é que em 164 pacotes por hora, configurações com 200 drones resultam em tempos de aproximadamente 14,5 horas, enquanto 500 drones mantêm o valor próximo de 2,7 horas. No ponto inicial, todas as configurações apresentam valores baixos e similares, indicando desempenho uniforme em baixas demandas. No ponto final, a estabilização é mais evidente para 500 drones, enquanto para 100 drones os valores continuam aumentando. Assim, o aumento no número de drones reduz consideravelmente os tempos de missão, já que o tempo médio de missão (TMM) aumenta principalmente devido ao maior acúmulo de pacotes no sistema em altas taxas de chegada.

Os resultados apresentados na Figura 3b apresentam a utilização dos drones em função da taxa de chegada. Para 100 drones a utilização alcança 80% rapidamente, enquanto 500 drones, para a mesma taxa de chegada, mantêm valores em torno de 25%. O ângulo de crescimento é menos pronunciado à medida que o número de drones au-

menta, apontando um sistema mais balanceado. Como exemplo, em 87 pacotes por hora, a utilização é de 80% para 100 drones e abaixo de 50% para 400 drones, mostrando uma diferença no desempenho. Inicialmente, todas as configurações apresentam utilização baixa, o que indica maior capacidade de resposta a baixas demandas. No final, observa-se uma estabilização em utilizações altas.

A Figura 3c apresenta a taxa de entrega em função da taxa de chegada. A distância das linhas revela que para 100 drones a taxa de entrega se limita a cerca de 37 pacotes/h, enquanto 500 drones alcançam 186 pacotes/h. O ângulo de crescimento é consistente e linear em configurações com maior capacidade, enquanto é mais irregular para configurações menores. Um ponto de destaque é que, em 319 pacotes por hora, configurações com 400 drones atingem 150 pacotes/h, contra 74 pacotes/h para 200 drones. No ponto inicial, todas as configurações apresentam taxas de entrega equivalentes em baixas demandas. No final, as configurações com 500 drones demonstram capacidade de entrega superior em relação às demais.

Os resultados apresentados na Figura 3d mostram a relação entre a taxa de entrega e o peso de colisão. A distância entre as linhas é mais pronunciada em pesos de falha baixos, com taxas de 0,12 pacotes/h para 500 drones e abaixo de 0,05 pacotes/h para 100 drones. Em pesos de colisão de 0,5, observa-se que a taxa é de abaixo de 0,02 para 500 drones e abaixo de 0,01 para 100 drones. No ponto inicial, logísticas com drones em menores quantidades apresentam taxas de entrega mais baixas, mostrando limitações no sistema. No ponto final, todas as configurações convergem para taxas similares, indicando que condições de pesos elevados de colisão, ou seja, uma baixa segurança da operação, impactam profundamente a taxa de entrega independentemente do número de drones usado no sistema.

## **4.2. Estudo de Caso 2: Análise de Sensibilidade Usando DoE**

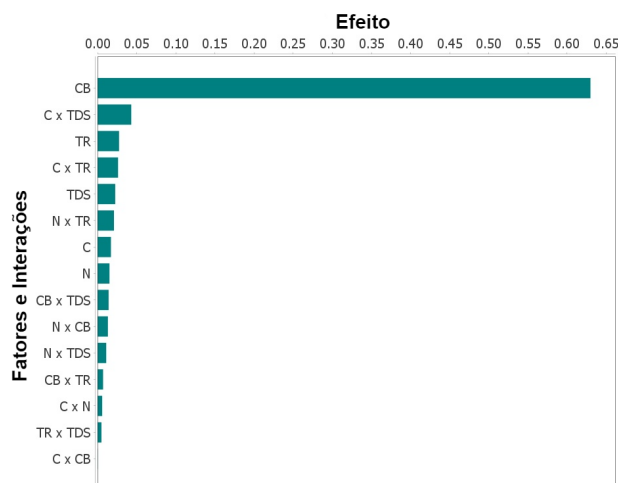
Esta seção descreve uma análise de sensibilidade conduzida usando o método DoE [Antony 2018]. O objetivo principal desta análise foi determinar quais componentes afetam significativamente o Tempo Médio de Missão e, assim, aprofundar nossa compreensão do processo de entregas feitas por drones em um contexto de colisão. Por meio do DoE, foi identificado os fatores que impactam na missão.

A Tabela 4 detalha os fatores e seus respectivos níveis, que foram manipulados durante o DoE. O nível de cada fator foi ajustado aumentando ou diminuindo-o em 50% de seu valor de base, com o AD fixado em 0,5 h. A Figura 4 apresenta os efeitos individuais e interativos dos fatores no TMM. Entre os fatores analisados, o tempo de recarga da bateria dos drones (CB) foi o mais influente. A interação entre a quantidade de drones (C) e o tempo de substituição dos drones (TDS) também teve impacto relevante, indicando que esses fatores, quando combinados, afetam diretamente o TMM. Por exemplo, uma baixa quantidade de drones tem pouco impacto no TMM isoladamente, mas afeta mais quando combinada com um alto tempo de substituição. O tempo de reparo (TR) também influenciou o resultado, especialmente em interação com a quantidade de drones (C).

A Figura 5 mostra a sensibilidade da interação entre diversos fatores. A Figura 5a apresenta a interação entre a quantidade de drones disponíveis (C) e o tempo de reparo dos drones (TR). Para TR igual a 180,0 h, o aumento de C de 250 para 750 reduz o TMM de aproximadamente 2,72 h para 2,68 h. Quando o C é 750, não importa se o TR for

**Tabela 4. Fatores e respectivos níveis.**

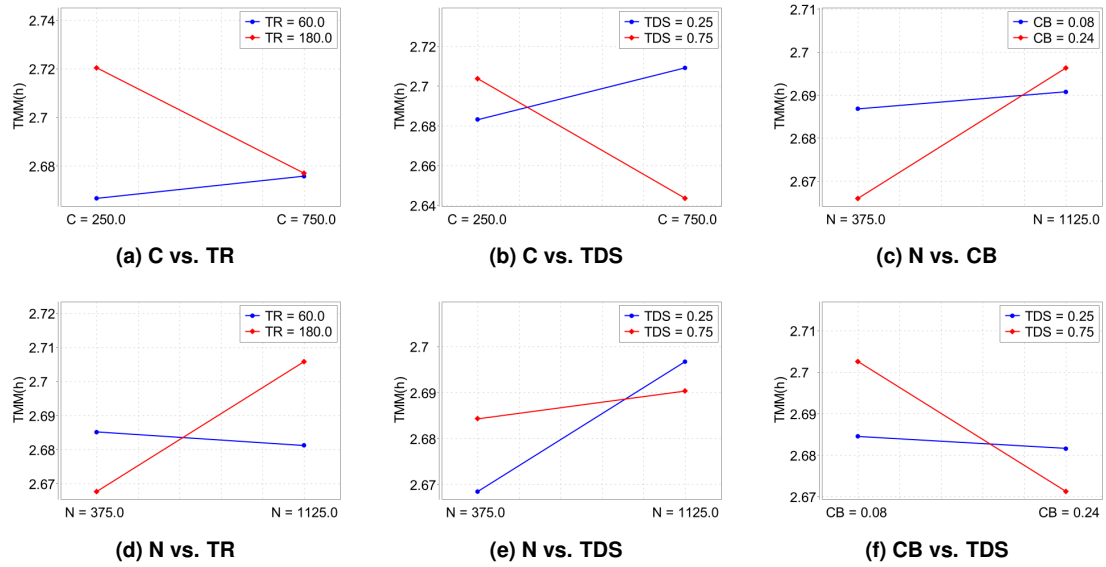
Fatores	Valor base - 50%	Valor base + 50%
C	250,0	750,0
N	375,0	1125,0
CB	0,08 h	0,24 h
TR	60,0 h	180,0 h
TDS	0,25 h	0,75 h



**Figura 4. Fatores e interações e seus respectivos efeitos.**

60,0 h ou 180,0 h, o TMM será aproximadamente o mesmo, não apresentando impacto significativo. Assim, se o sistema emprega um alto número de drones, o tempo de reparo praticamente não interfere no TMM. A Figura 5b mostra a interação entre a quantidade de drones disponíveis (C) e o tempo de substituição dos drones (TDS). Quando TDS é 0,75 h, o aumento de C de 250 para 750 reduz o TMM de aproximadamente 2,71 h para 2,64 h. Em contraste, para TDS igual a 0,25 h, o aumento de C resulta em um aumento no TMM, de 2,68 h para 2,72 h. Esses resultados mostram que, em cenários onde o tempo de substituição é maior, a expansão da frota de drones contribui para uma redução no Tempo Total da Missão. A Figura 5c mostra a interação entre o número de pacotes a serem entregues (N) e o tempo de recarga da bateria (CB). Quando CB é 0,24 h, o aumento de N de 375,0 para 1125,0 eleva o TMM de aproximadamente 2,67 h para 2,69 h. Em contrapartida, para CB igual a 0,08 h, o aumento de N tem um impacto insignificante. Esses resultados indicam que, em condições nas quais o tempo de recarga é maior, um aumento no número de pacotes a serem entregues resulta em variações mais perceptíveis no TMM. Por outro lado, quando CB é reduzido, o impacto do aumento de N no TMM é pequeno, tornando o ajuste do tempo de recarga menos crítico em cenários de alta demanda.

A Figura 5d apresenta a interação entre o número de pacotes a serem entregues (N) e o tempo de reparo dos drones (TR). Quando TR é 180,0 h, o aumento de N de 375,0 para 1125,0 resulta em um aumento do TMM de aproximadamente 2,67 h para 2,71 h. Em contraste, para TR igual a 60,0 h, o aumento de N tem um impacto inverso, reduzindo o TMM de 2,69 h para 2,68 h. Em cenários com tempos de reparo mais longos,



**Figura 5. Análise de sensibilidade em relação à interação entre fatores, com o Tempo Médio de Missão representado no eixo y.**

o aumento no número de pacotes causa um crescimento mais perceptível no TMM. Por outro lado, quando o tempo de reparo é menor, o aumento no número de pacotes não gera impacto significativo no desempenho, indicando que o tempo de reparo é um fator mais determinante nesses casos. A Figura 5e apresenta a interação entre o número de pacotes a serem entregues (N) e o tempo de substituição dos drones (TDS). Para TDS igual a 0,25 h, o aumento de N de 375,0 para 1125,0 resulta em um aumento do TMM, de 2,67 h para 2,70 h. Já para TDS de 0,75 h, o aumento de N tem um efeito mais discreto, com o TMM variando de 2,69 h para 2,70 h. A Figura 5f apresenta a interação entre o tempo de recarga da bateria (CB) e o tempo de substituição dos drones (TDS) sobre o Tempo Médio de Missão. Observa-se que o aumento de CB de 0,08 h para 0,24 h resulta em uma redução de TMM mais acentuada quando TDS é 0,75 h, passando de aproximadamente 2,71 h para 2,67 h. Com TDS igual a 0,25 h, o impacto do aumento de CB é pequeno, com o TMM variando de 2,68 h para 2,67 h. Em cenários onde o tempo de substituição dos drones é maior, ajustes no tempo de recarga podem contribuir para a redução do TMM. No entanto, em situações onde TDS é menor, mudanças em CB geram pouca variação no desempenho, mostrando que o tempo de recarga pode ser menos sensível a alterações nesses casos.

## 5. Conclusão

Neste trabalho, é proposto o uso de Redes de Petri Estocásticas para analisar o desempenho de serviços de entrega por drones. O modelo desenvolvido permite avaliar métricas como o tempo médio da missão, a utilização dos drones e a taxa de entrega de pacotes. Os resultados confirmam que o aumento no número de drones proporciona melhorias em todas as métricas analisadas, como redução de tempos, maior taxa de entrega e menor taxa de falhas. O modelo apresentado mostra-se configurável. Por exemplo, a análise de sensibilidade realizada utilizando o *Design* de Experimentos destaca o impacto do tempo de recarga da bateria no desempenho do sistema. Reduções no tempo de recarga resultam em melhorias no Tempo Médio de Missão (TMM), especialmente em cenários com

alta demanda e tempos curtos de substituição de drones. Por exemplo, em um cenário com 164 pacotes por hora e 200 drones, o TMM foi reduzido de 14,5 para 2,7 horas ao aumentar o número de drones para 500, destacando a importância do planejamento da frota. Para trabalhos futuros, pretende-se incorporar no modelo avaliações utilizando métricas de confiabilidade. Além disso, futuras avaliações incluirão o uso de simuladores, permitindo uma validação mais abrangente do modelo. Isso permitirá explorar aspectos como interação entre drones em voos cooperativos e otimização de rotas em ambientes tridimensionais.

## Agradecimentos

Este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo 2021/00199-8, CPE SMARTNESS.

## Referências

- Antony, J. (2018). Design of experiments: application concepts, examples, state of the art. *The TQM Journal*, 30(3):294–319.
- Bause, F. and Kritzinger, P. S. (2002). *Stochastic petri nets*, volume 1. Vieweg Wiesbaden.
- Behroozi, M. and Ma, D. (2023). Last mile delivery with drones and sharing economy. *arXiv preprint arXiv:2308.16408*.
- Bhuiyan, T. H., Walker, V., Roni, M., and Ahmed, I. (2024). Aerial drone fleet deployment optimization with endogenous battery replacements for direct delivery of time-sensitive products. *Expert Systems with Applications*, 252:124172.
- de Oliveira, F. M. C., Bittencourt, L. F., Bianchi, R. A. C., and Kamienski, C. A. (2024). Drones in the Big City: Autonomous Collision Avoidance for Aerial Delivery Services. *IEEE Transactions on Intelligent Transportation Systems*, 25(5):4657–4674.
- Devos, A., Ebeid, E., and Manoonpong, P. (2018). Development of autonomous drones for adaptive obstacle avoidance in real world environments. In *2018 21st Euromicro conference on digital system design (DSD)*, pages 707–710. IEEE.
- Dhote, J. and Limbourg, S. (2020). Designing unmanned aerial vehicle networks for biological material transportation—the case of brussels. *Computers & Industrial Engineering*, 148:106652.
- Du, L., Li, X., Gan, Y., and Leng, K. (2022). Optimal model and algorithm of medical materials delivery drone routing problem under major public health emergencies. *Sustainability*, 14(8):4651.
- Frizo Drone (2024). Reparos e Manutenção de Drones DJI. <https://frizodrone.com/assistencia-tecnica-dji>. Acessado em: 21 jan. 2025.
- Girault, C. and Valk, R. (2013). *Petri nets for systems engineering: a guide to modeling, verification, and applications*. Springer Science & Business Media.
- Hicks, A. (1959). Medrone. *British Medical Journal*, 1(5129):1121.
- Huang, C., Ming, Z., and Huang, H. (2023). Drone stations-aided beyond-battery-lifetime flight planning for parcel delivery. *IEEE Transactions on Automation Science and Engineering*, 20(4):2294–2304.

- Iqbal, D. and Buhnova, B. (2022). Model-based approach for building trust in autonomous drones through digital twins. In *2022 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 656–662. IEEE.
- Jain, R. (1990). *The art of computer systems performance analysis: techniques for experimental design, measurement, simulation, and modeling*. John Wiley & Sons.
- JOUAV (2024). How Much Does A Drone Cost in 2024 Here's a Price Breakdown. <https://www.jouav.com/blog/how-much-does-a-drone-cost.html>. Acessado em: 21 jan. 2025.
- Lord Drone (2024). Especialistas em Assistência Técnica DJI – Lord Care. <https://lordddrone.com.br/manutencao-de-drones>. Acessado em: 21 jan. 2025.
- Maciel, P., Matos, R., Silva, B., Figueiredo, J., Oliveira, D., Fé, I., Maciel, R., and Dantas, J. (2017). Mercury: Performance and dependability evaluation of systems with exponential, expolynomial, and general distributions. In *2017 IEEE 22nd Pacific Rim international symposium on dependable computing (PRDC)*, pages 50–57. IEEE.
- Mahulea, C., Recalde, L., and Silva, M. (2010). Observability of continuous petri nets with infinite server semantics. *Nonlinear Analysis: Hybrid Systems*, 4(2):219–232.
- Mateen, F. J., Leung, K. B., Vogel, A. C., Cisse, A. F., and Chan, T. C. (2020). A drone delivery network for antiepileptic drugs: a framework and modelling case study in a low-income country. *Transactions of The Royal Society of Tropical Medicine and Hygiene*, 114(4):308–314.
- Namiki, K. (2022). Modeling and simulation for optimizing drone operation rate by combining hybrid policies. In *2022 IEEE Global Conference on Life Sciences and Technologies (LifeTech)*, pages 162–166. IEEE.
- Rahman, M. S., Khalil, I., and Atiquzzaman, M. (2021). Blockchain-powered policy enforcement for ensuring flight compliance in drone-based service systems. *IEEE Network*, 35(1):116–123.
- Shi, Y., Lin, Y., Li, B., and Li, R. Y. M. (2022). A bi-objective optimization model for the medical supplies' simultaneous pickup and delivery with drones. *Computers & Industrial Engineering*, 171:108389.
- Silva, F. A., Barbosa, V., Sabino, A., Lima, L. N., Fé, I., Rego, P., and Bittencourt, L. F. (2024). Entregas Aéreas por Drones Cooperativos: Uma Avaliação de Desempenho Considerando Pontos de Recarga de Bateria. In *Anais do LI Seminário Integrado de Software e Hardware (SEMISH)*. SBC.
- Silva, L. G., Cardoso, I., Brito, C., Barbosa, V., Nogueira, B., Choi, E., Nguyen, T. A., Min, D., Lee, J. W., and Silva, F. A. (2023). Urban advanced mobility dependability: A model-based quantification on vehicular ad hoc networks with virtual machine migration. *Sensors*, 23(23):9485.
- Statista Research Department (2024). Global drone delivery market size 2021-2027. <https://www.statista.com/statistics/1302585/global-drone-delivery-service-market-size/>. Acessado em: 9 nov. 2024.