

Entregas Aéreas por Drones Cooperativos: Uma Avaliação de Desempenho Considerando Pontos de Recarga de Bateria

Francisco Airton Silva¹, Vandirleya Barbosa¹, Arthur Sabino¹
Luiz Nelson Lima¹, Iure Fé¹, Paulo Rego³ e Luiz F. Bittencourt²

¹PASID Lab, Universidade Federal de Piau  (UFPI)

²Instituto de Computa o, Universidade Estadual de Campinas (UNICAMP)

³Departamento de Computa o, Universidade Federal do Cear  (UFC)

{faps, vandirleya.barbosa, arthursabino, luizznelson, iure.fe}@ufpi.edu.br

bit@ic.unicamp.br, pauloalr@ufc.br

Resumo. *Em algumas cidades mais desenvolvidas do mundo j  existem iniciativas de entregas por drones em diversos tipos de servi os. Em termos tecnol gicos, h  um grande desafio relacionado ao tempo limitado de v o de tais dispositivos, causado principalmente pela limita o de bateria. Neste contexto, duas a o es podem mitigar este problema: usar pontos de recarga estrat gicos na cidade e adotar entregas cooperativas de m ltiplos drones. Ambas as a o es s o custosas. Este artigo prop e um modelo de redes de Petri estoc stico (SPN, do ingl s Stochastic Petri Nets) capaz de prever o n vel de utiliza o de drones cooperativos, bem como o tempo m dio e taxas de entrega. Tal predi o considera fatores importantes como uso de drones redundantes e inclus o do tempo de recarga em pontos estrat gicos.*

Abstract. *In some of the world's most developed cities, there are already drone delivery initiatives for various types of services. In technological terms, there is a major challenge related to the limited flight time of such devices caused mainly by battery limitations. In this context, two actions can mitigate this problem: using strategic charging points in the city and adopting cooperative deliveries of multiple drones. Both actions are costly. This article proposes a stochastic Petri net (SPN) model capable of predicting the level of use of cooperative drones, as well as the average time and delivery rates. This prediction considers important factors such as the use of redundant drones and the inclusion of recharging times at strategic points.*

1. Introdu o

Nos  ltimos anos, as empresas de log stica de entrega de produtos est o procurando evoluir tecnologicamente na forma como transportam mercadorias [Beigi et al. 2022]. O setor dos transportes ajudou a vida comum durante a pandemia da COVID-19 ao trazer servi os e bens essenciais  s pessoas e novas possibilidades, como o uso de drones para transporte de medicamentos. Muitos outros servi os e sistemas de entrega baseados em drones j  est o em funcionamento, a exemplo da empresa Zipline

[Flyzipline 2024]. Zipline é uma empresa americana que projeta, fabrica e opera drones de entrega. A empresa opera centros de distribuição como, por exemplo, Japão, Estados Unidos, Nigéria, Costa do Marfim e Quênia. Em novembro de 2023, os seus drones realizaram mais de 800.000 entregas comerciais e voaram mais de 40 milhões de milhas autônomas.

Apesar de promissor, drones voltados para entrega podem ter um custo elevado. Os drones de entrega podem custar entre alguns milhares de dólares e US\$ 60 mil [JOUAV 2024], dependendo do tamanho e da capacidade de carga, além de outros recursos. Esses drones normalmente usam Inteligências Artificiais (IA) para operar de forma independente, garantindo que possam evitar colisões no ar com outros drones e pousar com segurança por conta própria [Devos et al. 2018]. Considerando a possibilidade de usar um conjunto de drones para atender a uma demanda específica de entrega, faz-se necessário aplicar uma abordagem para entender e analisar o desempenho de drones antes de adquiri-los efetivamente. Redes de Petri estocásticas (SPNs) podem ser utilizadas para modelar e prever probabilisticamente o desempenho de drones, sendo ferramentas úteis para analisar a capacidade de atender um conjunto de demandas. SPNs são conhecidas pelo alto grau de representatividade, sendo mais intuitivos que opções convencionais, como cadeias de Markov, para representar concorrência, paralelismo, e sincronização em sistemas [Silva et al. 2023, Fé et al. 2023, Sousa et al. 2023]. Alguns trabalhos utilizam modelos analíticos relacionados ao problema aqui abordado, porém sem explorar, por exemplo, a chegada contínua de novas demandas de entrega. Visando ampliar a aplicabilidade dos drones e avaliar o desempenho de seu uso em uma escala mais abrangente, este trabalho utiliza modelos SPN capazes de antecipar o nível de utilização de drones cooperativos na entrega contínua de pacotes.

Para estender as opções para análises de desempenho das propostas mais recentes da literatura (Seção 2). Assim, neste artigo focamos em prever o tempo e a taxa de entrega de um conjunto de drones de forma cooperativa, considerando tempo de repasse de pacotes e tempo de recarga de bateria. Inspirado pelo trabalho de [Du et al. 2022], nosso trabalho propõe dois modelos SPN (Seção 4) para operações de entrega utilizando um ou dois drones por missão. Os modelos somam dezenove transições e vinte lugares que modelam dois possíveis cenários. O primeiro cenário possui um único drone para executar toda a missão de entrega. No segundo cenário há dois drones para efetuar a missão. Neste segundo cenário, se faz um repasse da entrega entre os drones, o que pode a princípio significar um ganho de desempenho em relação ao primeiro cenário. Os resultados numéricos (Seção 5) indicam que a taxa de chegada de novas entregas é um fator fundamental na decisão de usar mais ou menos drones, fazendo uso ou não de repasse de pacotes.

2. Trabalhos Relacionados

Esta seção apresenta os trabalhos relacionados que tratam do uso de drones para entrega de produtos. Foram encontrados ao todo sete artigos, os quais são sucintamente descritos a seguir. [Namiki 2022], com uso de redes de Petri, propõem a adoção de duas políticas de entrega por drones: uma global, que permite entregas entre três ou mais pontos, cobrindo uma ampla área com um número reduzido de drones. A outra política local usa drones exclusivamente entre dois pontos. [Shi et al. 2022] propõem um modelo de otimização para o problema de roteamento de localização de drones, permitindo coleta e entrega si-

multitêneas para reduzir o tempo de entrega de suprimentos médicos. [Mateen et al. 2020] propõem utilizar drones com um sistema de hub-and-spoke para a entrega eficiente de medicamentos antiepilépticos em áreas urbanas de baixa renda, visando contornar congestionamentos e reduzir o tempo de entrega.

O estudo de [Du et al. 2022] propõe um modelo de otimização para o roteamento de drones durante emergências de saúde pública, visando eficientemente entregar materiais médicos. O modelo considera o tempo total de viagem e as janelas de tempo de serviço ao cliente. O trabalho de [Dhote and Limbourg 2020] propõe explorar o uso de drones no transporte de materiais biomédicos, analisando o ambiente operacional desses dispositivos. Além disso, desenvolvem modelos de localização para o transporte de produtos biomédicos entre instalações de saúde, demonstrando a utilidade de estações de recarga para ampliar as missões dos drones. [Iqbal and Buhnova 2022] analisam a confiança dos drones autônomos em um cenário de entrega de alimentos. Os autores apresentam um método de avaliação de confiabilidade em tempo real. Cada drone, consegue avaliar em tempo real a confiabilidade de outros drones com os quais interage.

A Tabela 1 compara pontos relevantes deste estudo com outras pesquisas na área. O primeiro critério de comparação, **Contexto**, mostra que a maioria dos trabalhos explora a área hospitalar. Acreditamos que isso se deve à necessidade de transporte rápido em caso de emergência e que normalmente medicamentos são viáveis de transporte por serem leves. Nosso modelo não foca em um contexto específico, pois o modelo é generalizável. Existem várias possíveis **Métricas** neste contexto, mas optamos por focar em três que julgamos englobar bem o desempenho de entrega (utilização, tempo médio de missão e taxa de entrega). O tempo médio de missão é o tempo total do pacote a ser entregue chegar na base até o drone voltar para a base após sua entrega. Tal métrica não existe na literatura até o momento. Sobre **Método de avaliação**, apenas um trabalho [Mateen et al. 2020] não usou modelos analíticos. Como destacado na Introdução, drones podem incorrer em um investimento inicial alto, tornando experimentos muitas vezes inviáveis. Nosso trabalho usa redes de Petri ao invés de cadeias de Markov, ao conseguir abstrair detalhes menores para poder representar mais fatores de um sistema complexo sem explosão de estados [Gemikonakli et al. 2009]. Diferente de todos os outros trabalhos, nosso modelo representa uma **Entrega contínua**, ou seja, o atendimento de uma taxa de chegada de novos pacotes para entrega. Inclusive, neste caso, consideramos na métrica de tempo total da missão o tempo que um pacote esperará até iniciar seu transporte. Nossa proposta também inclui **Recarga dos drones**, pois não podemos desconsiderar que os drones possuem baterias com capacidade limitada atualmente, exigindo pausas para recarregá-las. Por fim, em **Multiplicidade de drones**, como em outros trabalhos, consideramos o uso de drones paralelos não comunicáveis entre si. Neste artigo, por não utilizar simulação, não exploramos a questão de colisões.

3. Arquitetura

A Figura 1 apresenta o cenário base da arquitetura de entrega de pacotes por drones. Os drones são programados para realizar entregas de maneira inteligente, saindo do ponto de origem (A) em direção ao destino (C), com uma parada estratégica para recarga no ponto intermédio (B), inspirado pelo trabalho de [Dhote and Limbourg 2020]. Este

Tabela 1. Trabalhos relacionados.

Trabalho	Contexto	Métricas	Método de avaliação	Entrega contínua	Recarga nos drones	Multiplicidade dos drones \diamond
[Namiki 2022]	Genérico	Política de entrega e taxa de operação	Modelo PN	×	×	Paralelo**
[Shi et al. 2022]	Hospitalar	Energia, tempo e número de drones	Modelo de Otimização de Rota	×	×	Paralelo**
[Mateen et al. 2020]	Hospitalar	Tempo de resposta	Experimento	×	×	Individual
[Du et al. 2022]	Hospitalar	Tempo de viagem e tempo de atendimento	Modelo de Otimização de Rota	×	×	Paralelo**
[Dhote and Limbourg 2020]	Hospitalar	Número de viagens	Modelo matemático	×	✓	Individual
[Iqbal and Buhnova 2022]	Comida	Taxa de entrega e tempo de resposta	Modelo PN	×	×	Paralelo*
[de Oliveira et al. 2023]	Genérico	Taxa de colisão, número de drones e viagens sucedidas	Modelo Markov Chain e Simulação	×	×	Paralelo**
Este trabalho	Genérico	Utilização, tempo médio de missão e taxa de entrega e CDF	Modelo PN	✓	✓	Paralelo**

Nota \diamond : — Com comunicação entre drones (*) — Sem comunicação entre drones (**).

ponto intermediário deve ser cuidadosamente selecionado para garantir que esteja convenientemente localizado em relação à rota principal, permitindo uma recarga rápida e eficiente. Durante esse período, os drones são conectados a estações de recarga automatizadas que alimentam suas baterias, garantindo que estejam prontos para a próxima etapa da entrega. Após a recarga, os drones retomam sua jornada em direção ao ponto final (C). Ao chegar ao destino, os drones podem ser recarregados novamente, se necessário, para garantir que estejam prontos para futuras missões. A combinação de rotas otimizadas, recargas estratégicas e eficiência energética resultam em um sistema de entrega rápido, confiável e ecologicamente sustentável.

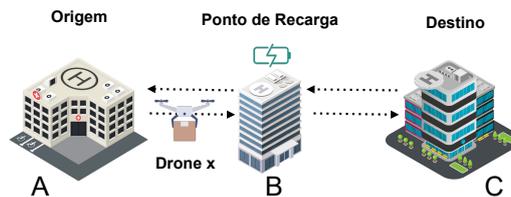


Figura 1. Visão geral do esquema de transporte de pacotes por drones considerando um ponto de recarga.

A Figura 2 representa o sistema utilizando apenas um único drone responsável por realizar a missão, todo o trajeto da entrega, desde o ponto de origem (A) até o destino (C) contemplando todas as recargas necessárias até o retorno para o ponto de origem. Esse modelo simplifica a operação, uma vez que um único veículo autônomo é encarregado de realizar a entrega completa. O fluxo do sistema está numerado em etapas, demonstrando o ciclo de uma missão onde um drone parte do ponto (A) até o ponto (C). O drone ao chegar no ponto (B) e (C) recarrega sua bateria para terminar sua missão.

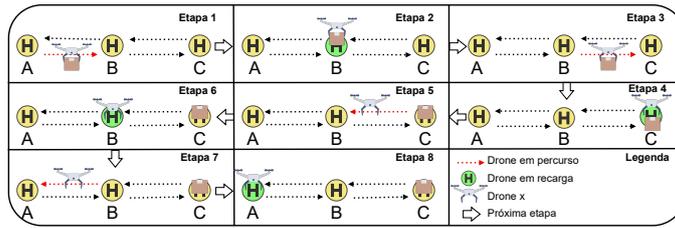


Figura 2. Ilustração passo a passo do sistema de transporte sem considerar repasse de pacotes.

Na Figura 3, ao chegar no ponto (B), o drone X repassa a entrega para o drone Y. Isso pode ser feito eficientemente, aproveitando a infraestrutura de recarga no ponto (B). O drone X após carregado retorna para o ponto de origem (A), enquanto o drone Y fica responsável pela conclusão da missão realizando a entrega no ponto (C) com todas as respectivas recargas. Ao final de cada percurso percorrido pelo drone é efetuado a recarga no ponto determinado para o prosseguimento da missão, ou retorno para origem.

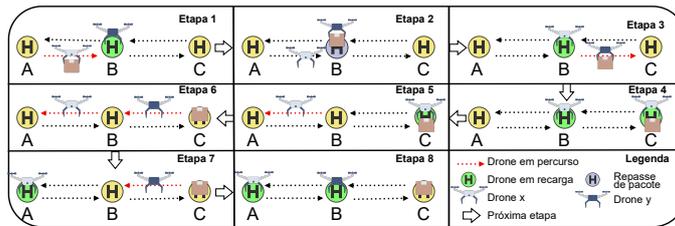


Figura 3. Ilustração passo a passo do sistema de transporte considerando repasse de pacotes.

4. Modelos SPNs Propostos

Esta seção apresenta os modelos elaborados considerando as características específicas das duas arquiteturas propostas. Os modelos foram construídos e simulados na ferramenta Mercury (versão 5.0.1) [Maciel et al. 2017]. Esta ferramenta vem sendo usada para modelar inúmeras aplicações computacionais em diversos contextos [Silva et al. 2023, Fé et al. 2023, Correia et al. 2023]. As Figuras 4 e 5 apresentam os dois modelos SPN propostos, onde 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].

A Figura 4 (com a respectiva descrição dos componentes na Tabela 2) destaca a estrutura do modelo considerando a arquitetura sem repasse de pacotes. A fase inicial do sistema refere-se à recepção de pacotes no sistema de entrega, no qual T_1 representa o intervalo entre as chegadas dos pacotes para entrega. O lugar P_a marca o ponto do percurso onde os pacotes de entrega entram no sistema, e no lugar P_{cfd} (marcação ND), os drones de entrega aguardam em posição. A ativação da transição T_{ab} indica que os drones de entrega receberam os pacotes e estão partindo em uma missão de entrega, iniciando em A para o destino B. No ponto do percurso representado pelo lugar P_b , que simboliza a chegada ao destino B, os drones recarregam na transição T_{chb} antes de prosseguirem com a entrega. Após a recarga, os drones estão prontos para continuar o

trajeto no lugar P_{bc} , partindo de B para C na transição T_{bc} , até atingirem o destino C no lugar P_c . Ao chegar em P_c , a transição T_{chc} é acionada para iniciar o recarregamento, preparando-se no local P_{cbv} para a jornada de retorno. Para iniciar o trajeto de volta, a transição T_{cb} encaminha os drones da origem C para o destino B. No lugar P_{bv} , os drones alcançam o destino B e realizam a recarga da bateria na transição T_{chbv} . Quando a bateria está carregada, eles se preparam no lugar P_{bav} para iniciar o trajeto de retorno, saindo da origem B para o destino A, conforme indicado pela transição T_{ba} . A chegada ao destino A (lugar P_{av}) é marcada pela transição T_{hav} , onde ocorre a recarga, e os drones aguardam em posição no lugar P_{cfd} para iniciar uma nova missão.

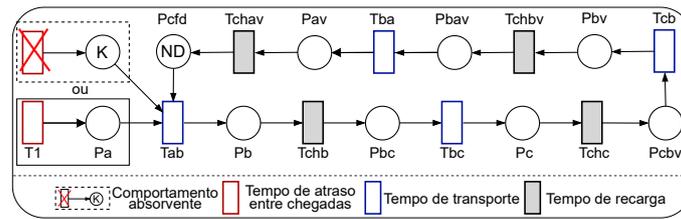


Figura 4. Modelo SPN considerando arquitetura sem repasse de pacotes.

Tabela 2. Descrição dos principais componentes dos modelos SPN.

Tipo	Componente(s)	Descrição
Lugares	P_a, P_b, P_c	Pontos do trajeto considerando a ida.
	P_{bc}	Drone pronto para ir do ponto B para o C.
	P_{cbv}, P_{bav}	Drones prontos para voltar entre os pontos C e B; e B e A respectivamente.
Transições temporizadas	P_{av}, P_{bv}	Drones prontos para voltar para A e B respectivamente.
	P_{bv1}, P_{bv2}	Pontos do trajeto considerando a volta dos drones que fazem repasse.
	$T_{ab}, T_{bc}, T_{cb}, T_{ba}$	Tempos de transporte entre os pontos respectivos.
	T_{chb}, T_{chc}	Tempos de recarga nos pontos b e c considerando a ida.
	T_{chav}, T_{chbv}	Tempos de recarga nos pontos b e c considerando a volta.
Lugares marcados	T_{chb1v}, T_{chb2v}	Tempos de recarga no ponto b considerando os drones que fazem repasse.
	T_{trf}	Tempo de repasse de pacote entre os drones.
Lugares marcados	$ND, ND2$	Número máximo de drones paralelos por missão.

O modelo proposto neste trabalho também pode calcular a amplamente utilizada função de distribuição cumulativa (CDF). Com a CDF, é possível estimar a probabilidade (entre 0 e 1) de terminar a execução antes de um tempo específico $[P(T < t)]$. Tal métrica pode ser calculada em modelos de redes de Petri analisando a probabilidade de não haver mais movimentação dos tokens (estado absorvente) [Bobbio 1990]. Na Figura 4 é apresentado o modelo e sua respectiva alteração para que o cálculo do CDF seja efetuado. Esta alteração trata-se de eliminar a transição geradora de novas requisições e adicionar um valor de K requisições já armazenadas na fila de entrada. Importante destacar que as transições que representam o tempo de recarga são determinísticas por possuírem um tempo fixo de recarga.

A Figura 5 apresenta o modelo da arquitetura com o repasse de pacotes entre os drones de entrega. Para facilitar a compreensão e evitar redundâncias, concentraremos nossa atenção nas distinções entre os modelos com e sem o repasse de pacotes. O funcionamento geral deste modelo é semelhante ao apresentado na Figura 4, envolvendo o recebimento, envio, recarga e tempo de transporte de pacotes. No entanto, a característica distintiva deste modelo reside na transição temporizada T_{trf} representando o repasse

do pacote. Quando o token atinge esta transição, ocorre a replicação de tokens para os lugares P_{bv1} e P_{bc} . Essa ação representa o momento em que um drone entrega o pacote a outro drone disponível para dar continuidade à missão. O drone que alcança essa transição pode retornar ao ponto inicial, seguindo o padrão de recarga e transporte, e tornar-se novamente disponível no lugar P_{cfd} . Observe que existem dois *pools* de drones, um para cada trecho, com as marcações ND e ND2. O drone que recebeu o repasse da carga segue o mesmo padrão operacional até atingir seu destino. Ao chegar no lugar P_{10} , ele volta a ficar disponível para receber novos pacotes para transferência. O modelo mantém esse padrão mesmo quando vários drones estão em operação, trabalhando de maneira contínua. As modificações realizadas para tornar o modelo absorvente (na parte de entrada de requisições) segue o mesmo padrão do modelo sem repasse. É válido ressaltar que, em ambos os modelos, para a realização das simulações e geração de resultados, foram feitas abstrações em relação a interferências externas, como condições climáticas (vento, temperatura, umidade, etc.).

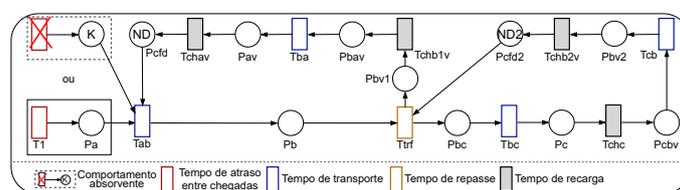


Figura 5. Modelo SPN considerando arquitetura com repasse de pacotes.

4.0.1. Métricas

O tempo médio de resposta (*MRT*) pode ser obtido a partir da Lei de Little [Jain 1990]. Esta lei requer um sistema estável, ou seja, que possua uma taxa de requisições menor que a taxa de processamento dos servidores. A lei indica que o Tempo Médio de Resposta (*MRT*), no nosso caso denominado como o Tempo Médio da Missão (*TMM*), é dado pela divisão do número médio de requisições em progresso em um sistema (*RequestsInProgress*) pela taxa de chegada de novas entregas (*AR*). A taxa de chegada é o inverso do tempo entre chegadas. O tempo entre chegadas abreviamos aqui para *AD*. O valor de *RequestsInProgress* é dado pela soma de tokens em cada um dos locais que representam uma requisição em andamento. $E_{nomedolocal}$ representa a esperança estatística de existir tokens em “nomedolocal”, onde $E_{nomedolocal} = (\sum_{i=1}^n P(m(Local) = i) \times i)$, sendo n o maior número de tokens que o *Local* pode conter. Em outras palavras, $E_{nomedolocal}$ indica o valor esperado de tokens naquele Local. Portanto, as equações para calcular o tempo médio da missão para os dois modelos são mostradas na Tabela 3.

O nível de utilização de recursos é calculado somando-se a quantidade de recursos utilizados e dividindo pela capacidade total previamente disponível. Para o modelo da Figura 4, por exemplo, soma-se todos os valores esperados dos lugares após a transição T_{ab} e antes da transição T_{chav} e divide pelo valor de ND. Fazemos a multiplicação por 100, pois o valor do modelo a princípio é dado entre 0 e 1 pelo Mercury. Para o modelo com repasse consideramos a capacidade total, somando ND e ND2. Por fim, a taxa de entrega é calculada como uma taxa de vazão. Para este tipo de modelo com transição *infinite server* basta dividir o número de tokens enfileirados em um lugar e dividir pelo

tempo da transição subsequente. Desta forma, a taxa de entrega (TE) considera a divisão do valor esperado de E_{Pbc} pelo tempo de transporte do trecho em questão.

Tabela 3. Expressões utilizadas para a obtenção das métricas deste estudo.

Métrica	Modelo com repasse	Modelo sem repasse
TMM	$(E_{Pa} + E_{Pb} + E_{Pbv1} + E_{Pbav} + E_{Pav} + E_{Pbc} + E_{Pc} + E_{Pcbv} + E_{Pbv2}) \times AD$	$(E_{Pa} + E_{Pb} + E_{Pbc} + E_{Pc} + E_{Pcbv} + E_{Pbv} + E_{Pbav} + E_{Pav}) \times AD$
U	$((E_{Pb} + E_{Pbv1} + E_{Pbav} + E_{Pav} + E_{Pbc} + E_{Pc} + E_{Pcbv} + E_{Pbv2}) / (ND + ND2)) \times 100$	$((E_{Pb} + E_{Pbc} + E_{Pc} + E_{Pcbv} + E_{Pbv} + E_{Pbav} + E_{Pav}) / ND) \times 100$
TE	$E_{Pbc} / \text{Tempo de transporte}$	

5. Estudo de Caso

Nesta seção apresentamos um estudo de caso utilizando o modelo proposto. O estudo é útil tanto para obtenção de novas descobertas sobre o funcionamento do modelo, e consequentemente do sistema real, como também ilustrar como o modelo pode ser explorado. Nos estudos de caso a seguir variamos a taxa de chegada de 1 até 20 pacotes por hora. Para a configuração dos parâmetros utilizados para alimentar o modelo, temos três componentes: tempo médio de transporte com um tempo de 0,5 horas, tempo médio de recarga com 0,16 horas e tempo médio de repasse com 0,03 horas. Tais tempos médios foram baseados no artigo de [Namiki 2022]. Vale ressaltar que esses parâmetros são configuráveis e podem ser diferentes para cada realidade a depender do tipo de drone, distâncias, etc.

5.1. Estudo de Caso 01 - Comparação Entre as Estratégias de Entrega

A Figura 6 apresenta a comparação entre as duas estratégias de entrega, com e sem repasse. Nesse cenário, a capacidade máxima de drones paralelos para a estratégia sem repasse foi de dez drones e, com repasse, vinte drones (somando os dois trechos). Por ter uma capacidade maior de trabalho, é esperado que, geralmente, a estratégia com repasse possua um desempenho melhor do que sem repasse. Em outras palavras, o tempo de missão menor, a utilização menor e a taxa de entrega maior. No entanto, é interessante notar que isso dependerá da taxa de chegada (AR). Para o Tempo Médio da Missão (Figura 6(a)), com $AR \leq 4pct/h$, o desempenho é praticamente igual. Após este ponto, a diferença gira em torno de trinta horas entre as duas estratégias. Para a Utilização (Figura 6(b)), com $AR = 1pct/h$, a diferença de utilização é de 15%. Com $AR = 3pct/h$, a diferença de utilização é de 40%. Para a Taxa de Entrega (Figura 6(c)), com $AR \leq 4pct/h$, as taxas de entrega são iguais. Após este ponto a diferença passa para aproximadamente três pacotes por hora.

Analisamos agora separadamente a Figura 6(d) pois esta não depende de uma taxa de chegada. Como destacado na Seção 4, para cálculo do CDF, consideramos que os pacotes já estão aptos a serem entregues na base. Para este exemplo, consideramos $K = 50$ pacotes. Observa-se que a probabilidade de entrega da estratégia com repasse é maior do que sem repasse entre os tempos 14 e 17h. A probabilidade de entrega de todos os pacotes após 18h é igual para as duas estratégias. Tomando um ponto específico de tempo como exemplo, com 16h a estratégia sem repasse possui $P(T \leq t) = 75\%$ e com repasse $P(T \leq t) = 89\%$.

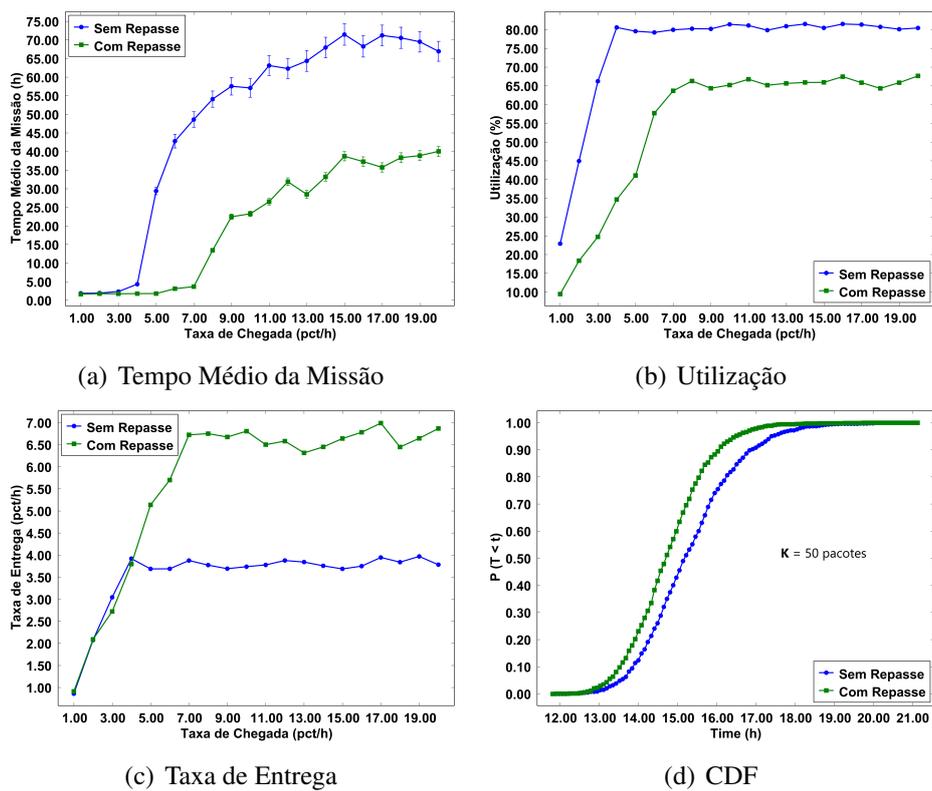


Figura 6. Comparando as duas estratégias de entrega.

5.2. Estudo de Caso 02 - Variação do Número Máximo de Drones Com Repasse

Os resultados apresentados daqui em diante focam com mais detalhes na estratégia com repasse por apresentar melhor desempenho do que estratégias sem repasse. Neste caso, para as três métricas, variamos a capacidade dos dois trechos da seguinte forma: $ND + ND2 = [8, 16, 32, 64]$. Também ilustramos um conjunto de requisitos a serem obedecidos. Quando um novo negócio de entregas vai ser implantado, deve haver uma previsão de qual será a demanda de entregas, bem como qual o nível de qualidade de tais entregas. Os requisitos, portanto, são exigências numéricas previamente estabelecidas para a modelagem dar indicações de qual configuração será mais adequada. A análise pode auxiliar na decisão de quantos drones serão necessários para alcançar tais requisitos. Abreviamos aqui os requisitos como “Reqs” e a definimos para cada métrica a seguir.

A Figura 7(a) mostra os resultados para a métrica de tempo médio da missão. À medida que se aumenta o número de drones paralelos se têm um menor valor de MTT. Até AR até 2pct/h, o valor de MTT é igual para todos. Para sessenta e quatro drones, como há quase uma ausência de gargalo (ver Figura 7(b)), o valor de MTT é sempre de aproximadamente 1,7h. Com oito drones, o MTT chega a 90h, um valor muito alto considerando, por exemplo, entregas na área da saúde que podem representar risco de vida. Para o MTT, analisamos $Reqs = (15pct/h \leq AR \leq 20pct/h) \text{ AND } (TMM \leq 60h)$. Observando o quadro amarelo, temos que apenas as quantidades 16, 32 e 64 atendem o requisito relacionado ao MTT. Obviamente, caso o avaliador não tenha outro sub requisito, a escolha mais econômica (16 drones) seria a mais atrativa.

A Figura 7(b) mostra os resultados para a métrica de utilização. À medida que se

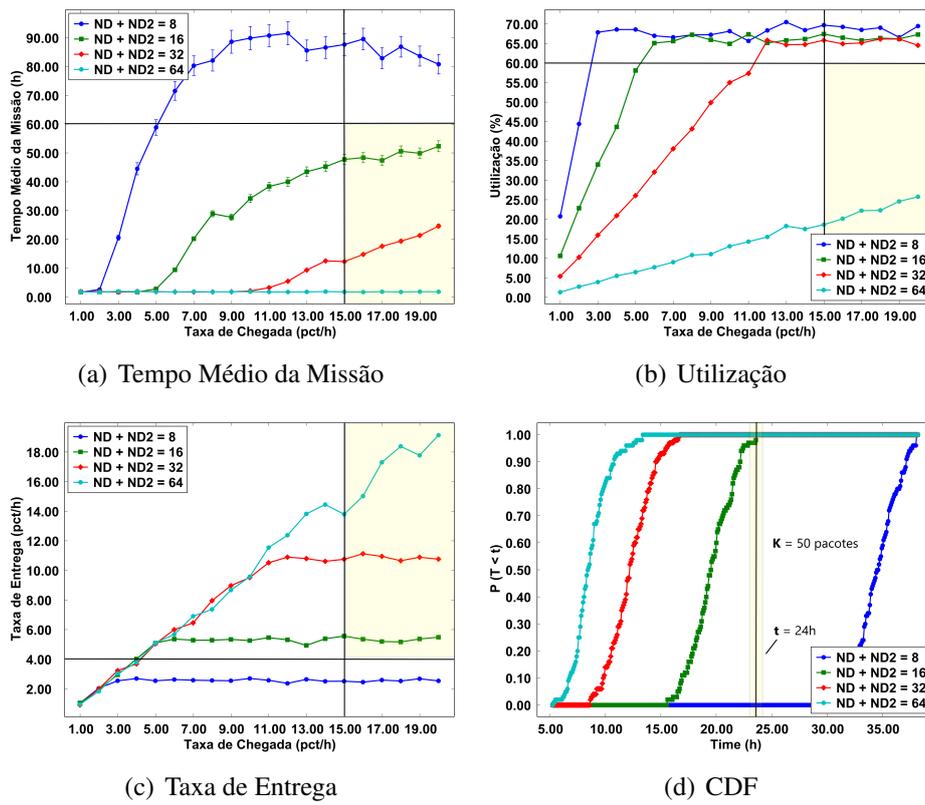


Figura 7. Comparando as duas estratégias de entrega.

Quando se aumenta o número de drones paralelos, tem-se um menor valor de U . Com $AR=1pct/h$, as utilizações de cada configuração já são diferentes e com o aumento de AR a discrepância se amplia. As configurações com 8, 16 e 32 atingem um pico de utilização e estagnação em 65%, indicando que em tais situações o sistema está tendo dificuldade para entregar tantos pacotes. Porém, vale ressaltar que com 8 drones (3pct/h) o pico é atingido bem antes do que com 32 drones (13pct/h). Para U , analisamos $Reqs = (15pct/h \leq AR \leq 20pct/h) \wedge (U \leq 60\%)$. Finalmente, sobre o requisito, apenas a configuração de 64 drones obterá uma utilização abaixo do que 60% no intervalo de AR exigido. Como a linha está disposta bem abaixo do exigido, o avaliador neste caso poderia testar outros valores de capacidade entre 32 e 64.

A Figura 7(c) mostra os resultados para a métrica de taxa de entrega. O comportamento padrão de valores relacionados à taxa de processamento é ter um crescimento aproximadamente linear e estacionar em um certo ponto. Neste caso, tal estagnação ocorre para os valores de 8, 16 e 32 drones, porém não ocorre para 64 drones no intervalo analisado. Até $AR=3pct/h$, as taxas de entrega são iguais para todas as configurações. Para TE , analisamos $Reqs = (15pct/h \leq AR \leq 20pct/h) \wedge (TE \geq 4h)$. Novamente, sobre o requisito desejado, os valores da taxa de entrega foram satisfatórios para 16, 32 e 64 drones.

A Figura 7(d) mostra os resultados para a métrica de CDF. Como no estudo de caso 01, aqui também exploramos a probabilidade de entregar 50 pacotes. As probabilidades de 32 e 64 drones são semelhantes. Com 64 drones se chega à probabilidade 100% de entrega por volta de 12h. Com 32 drones se chega à probabilidade 100% de entrega por

volta de 14h. Até 30h, a probabilidade de término com 8 drones é igual a 0. Finalmente, para CDF, analisamos $Reqs = (P(T \leq 24h) = 100\%)$. Tal requisito é alcançado com 16, 32 e 64 drones.

6. Conclusão

Neste trabalho foi proposto o uso de SPN para analisar o desempenho de serviços de entregas por drones. Os modelos consideram métricas relacionadas ao tempo médio da missão, utilização dos drones e taxa de entrega de pacotes. Os modelos necessitam ser alimentados por parâmetros relacionados, por exemplo, ao tempo médio de autonomia de voo do drone, que podem ser obtidos das especificações técnicas do drone antes de adquiri-los. Os modelos apresentados são altamente configuráveis. Por exemplo, nós consideramos tempos de recarga, mas o avaliador pode alterar por tempos de substituições da bateria do drone, o que pode resultar em tempos de missões reduzidos. Os estudos de caso mostraram que o modelo pode ser usado no planejamento de capacidade para atender um determinado requisito de logística. Como trabalhos futuros pretendemos usar algoritmos de otimização para melhorar ainda mais os resultados para atender mais precisamente os requisitos tentando diminuir custos. Pretende-se também incluir no modelo, probabilidades de colisões à medida que se aumenta o número de drones.

Referências

- Beigi, P., Khoueiry, M., Rajabi, M. S., and Hamdar, S. (2022). Station reallocation and rebalancing strategy for bike-sharing systems: A case study of washington dc. *arXiv preprint arXiv:2204.07875*.
- Bobbio, A. (1990). System modelling with petri nets. In *Systems Reliability Assessment: Proceedings of the Ispra Course held at the Escuela Tecnica Superior de Ingenieros Navales, Madrid, Spain, September 19–23, 1988 in collaboration with Universidad Politecnica de Madrid*, pages 103–143. Springer.
- Correia, L. F., Dantas, J. R., and Silva, F. A. (2023). Blockchain as a service environment: a dependability evaluation. *The Journal of Supercomputing*, pages 1–25.
- de Oliveira, F. M., Bittencourt, L. F., Bianchi, R. A., and Kamienski, C. A. (2023). Drones in the big city: Autonomous collision avoidance for aerial delivery services. *IEEE Transactions on Intelligent Transportation Systems*.
- 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.

- Fé, I., Nguyen, T. A., Soares, A., Son, S., Choi, E., Min, D., Lee, J.-W., and Silva, F. A. (2023). Model-driven dependability and power consumption quantification of kubernetes based cloud-fog continuum. *IEEE Access*.
- Flyzipline (2024). American company that designs, manufactures, and operates delivery drones. <https://www.flyzipline.com/> Acessado em: 04/01/2024.
- Gemikonakli, O., Ever, E., and Kocyigit, A. (2009). Approximate solution for two stage open networks with markov-modulated queues minimizing the state space explosion problem. *Journal of Computational and Applied Mathematics*, 223(1):519–533.
- Girault, C. and Valk, R. (2013). *Petri nets for systems engineering: a guide to modeling, verification, and applications*. Springer Science & Business Media.
- 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: 04/01/2024.
- 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., Cissé, 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 (2022). Modeling and simulation for optimizing drone operation rate by combining hybrid policies. In *2022 IEEE 4th Global Conference on Life Sciences and Technologies (LifeTech)*, pages 162–166. IEEE.
- 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, 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.
- Sousa, R. d., Cristian, L., Feitosa, L., Choi, E., Nguyen, T. A., Min, D., and Silva, F. A. (2023). Performability evaluation and sensitivity analysis of a video streaming on demand architecture. *Applied Sciences*, 13(2):998.