

Análise da Pontualidade da Informação em Redes Long-Range Frequency Hopping Spread Spectrum

João Mateus Ambrósio, Jamil Farhat, João Luiz Rebelatto e Glauber Brante

Resumo— Neste trabalho, investigamos o desempenho da técnica *Long-Range Frequency Hopping Spread Spectrum* (LR-FHSS), com foco na relação de *trade-off* entre *goodput* e Pontualidade da Informação (em inglês *Age of Information*, AoI). Especificamente, avaliamos o desempenho de diferentes taxas de dados (em inglês *Data Rates*, DR) padronizadas do LR-FHSS, analisando como essas métricas se relacionam entre configurações de DR diversas. Nossos resultados numéricos demonstram que uma análise baseada apenas no *goodput* é insuficiente em cenários onde a atualização da informação é crítica. Além disso, mostramos que configurações de transmissão não padronizadas podem apresentar melhor desempenho, dependendo dos parâmetros e configurações da rede.

Palavras-Chave— LR-FHSS, Pontualidade da Informação, Internet das Coisas.

Abstract— In this work, we analyze the performance of Long-Range Frequency Hopping Spread Spectrum (LR-FHSS), focusing on the trade-off between goodput and Age of Information (AoI). Specifically, we evaluate different standardized LR-FHSS Data Rates (DR), examining how these metrics behave under different DR configurations. Our numerical results show that relying exclusively on the goodput optimization is inadequate in applications where information freshness is crucial. Furthermore, we demonstrate that non-standard transmission settings can achieve superior performance depending on network parameters and deployment conditions.

Keywords— LR-FHSS, Age of Information, Internet of Things.

I. INTRODUÇÃO

A Internet das Coisas (em inglês *Internet of Things*, IoT) tem experimentado crescimento exponencial, impulsionando aplicações em diversos domínios [1]. Este fenômeno tecnológico está transformando radicalmente setores como cidades inteligentes, agricultura de precisão, saúde conectada e Indústria 4.0, criando ecossistemas de dispositivos interconectados que coletam, processam e trocam dados em tempo real. Segundo projeções recentes, estima-se que existirão cerca de 39,6 bilhões de dispositivos IoT conectados até 2033, um aumento significativo sobre os 13,8 bilhões de dispositivos de 2022 [2].

Este cenário de crescimento acelerado demanda o desenvolvimento de tecnologias de comunicação capazes de suportar grande densidade de dispositivos mantendo requisitos essenciais de baixo consumo energético, característica fundamental para a IoT massiva (em inglês *massive IoT*, mIoT) [3]. Os desafios técnicos incluem não apenas a escalabilidade da rede,

mas também a garantia de confiabilidade na comunicação, eficiência espectral e longa duração da bateria dos dispositivos, que frequentemente operam com restrições severas de energia.

No contexto das soluções de comunicação para IoT, as Redes de Longo Alcance e Baixo Consumo (em inglês *Low Power Wide Area Networks*, LPWAN) são fundamentais, oferecendo cobertura ampla com baixo consumo de energia [4]. Entre as diversas tecnologias LPWAN, o LoRaWAN (*Long Range Wide Area Network*) destaca-se por sua arquitetura aberta, operação em bandas não licenciadas e capacidade de suportar comunicações de longo alcance [5].

Introduzida originalmente para operar sobre a modulação LoRa (patenteada pela Semtech e que se baseia no conceito de *chirp spread spectrum* - CSS [6]), LoRaWAN incorporou recentemente a técnica LR-FHSS (em inglês *Long Range Frequency Hopping Spread Spectrum*) como forma de expandir a capacidade da rede e aumentar sua robustez contra interferências, representando um avanço significativo para aplicações que demandam alta confiabilidade [7].

O LR-FHSS opera dividindo o *payload* (PL), em fragmentos codificados que são transmitidos através de saltos pseudo-aleatórios de frequência, enquanto também envia múltiplas réplicas do cabeçalho (em inglês *header*, HD) em diferentes frequências. Esta abordagem híbrida combina as vantagens do espalhamento espectral com a diversidade de frequência, melhorando significativamente a resiliência a interferências e a escalabilidade do LoRa [8], [9].

A literatura recente apresenta avanços significativos na compreensão e aprimoramento do LR-FHSS. Por exemplo, [10] apresenta modelos analíticos para avaliar o desempenho em redes satelitais diretas, enquanto [11] investiga o impacto da probabilidade de sucesso do cabeçalho na confiabilidade geral do sistema. Em acréscimo, [12] propõe o desenvolvimento de técnicas de detecção de sinais com baixa complexidade, enquanto [13] explora um protocolo de diversidade Aloha com resolução assíncrona de contenção para mitigar colisões. Por fim, recentemente em [14], os autores investigam a probabilidade de colisão de pacotes no *uplink* de redes IoT satelitais considerando diferentes parâmetros dos satélites e comparando LoRa e LR-FHSS. Esses trabalhos demonstram o crescente interesse da comunidade científica em otimizar o desempenho do LR-FHSS para diferentes cenários operacionais.

Além dos desafios tradicionais de capacidade e eficiência energética, as aplicações IoT modernas demandam novas métricas de desempenho. Métricas convencionais como latência e taxa de transferência mostram-se insuficientes para avaliar adequadamente a pontualidade da informação em aplicações críticas. Neste contexto, a Pontualidade da Informação (em inglês *Age of Information*, AoI) emerge como métrica funda-

J. M. Ambrósio, Departamento Acadêmico de Eletrotécnica (DAELT), Universidade Tecnológica Federal do Paraná (UTFPR), Curitiba-PR. E-mail: joaoambrosio@alunos.utfpr.edu.br.

J. Farhat, J. L. Rebelatto e G. Brante, Programa de Pós-Graduação em Engenharia Elétrica e Informátics Industrial (CPGEI), UTFPR, Curitiba-PR. E-mails: {jamilfarhat, jlrebelatto, gbrante}@utfpr.edu.br.

mental para quantificar quão atuais (ou “frescos”) são os dados recebidos no destino [15], sendo particularmente relevante para sistemas IoT [16]. A AoI avalia não apenas o tempo de transmissão, mas também o tempo desde a geração da informação, oferecendo uma visão mais completa da utilidade dos dados recebidos. Assim, destaca-se em aplicações onde a temporalidade da informação é crucial, como em sistemas de monitoramento industrial, redes de sensores para saúde, sistemas de controle em tempo real, entre outros [17].

A partir da literatura acima citada, este trabalho propõe a investigação do impacto das diferentes configurações do protocolo LR-FHSS em sua AoI, avaliando em paralelo a troca de benefícios (*tradeoff*) entre AoI e taxa de transmissão líquida (*goodput*) da rede. Especificamente, analisamos os efeitos das diferentes configurações em termos da taxa de codificação e réplicas de cabeçalhos em diversos cenários operacionais. Tal investigação é realizada a partir da abordagem baseada no simulador LR-FHSS-Sim [18], que permite variar parâmetros críticos como densidade de dispositivos, além de avaliar o desempenho do sistema sob diferentes configurações operacionais. Desta forma, este estudo investiga a relação entre eficiência espectral e atualidade da informação, fornecendo *insights* valiosos para o projeto e otimização de redes IoT baseadas em LR-FHSS. Por fim, vale ressaltar que, até onde os autores tem conhecimento, este é o primeiro trabalho que explora a medida da AoI no contexto do LR-FHSS, contribuindo para preencher uma lacuna importante na literatura técnica.

O restante deste documento está organizado da seguinte forma. A Seção II apresenta brevemente as especificações do LR-FHSS e introduz a métrica da AoI. A Seção III apresenta o modelo de sistema empregado, enquanto a Seção IV apresenta alguns resultados numéricos para avaliar seu desempenho. Por fim, a Seção V conclui o artigo.

II. CONCEITOS

O LR-FHSS é uma técnica de modulação recentemente incorporada à especificação do LoRaWAN, cujo principal objetivo é aumentar a capacidade de *uplink*, proporcionando um desempenho superior em redes densas atendidas por um único *gateway*, como é o caso das redes satelitais [19]. No LR-FHSS, a largura de banda total disponível é dividida em 8 *grids* de frequência. Cada *grid* é subdividido em c canais de 488 Hz, sendo que os saltos de frequência ocorrem entre esses canais dentro de um mesmo *grid* [13]. A estrutura desses *grids* é ilustrada na Figura 1.

A transmissão de um pacote LR-FHSS envolve tanto o envio do cabeçalho quanto de *payload*. Para aumentar a robustez contra eventos de colisão, um dispositivo IoT envia múltiplas cópias do cabeçalho sequencialmente em diferentes canais, conforme ilustrado na Figura 1, em que cada um dos 3 dispositivos ilustrados envia duas cópias de seus respectivos cabeçalhos. Adicionalmente, o *payload* é codificado por um código convolucional e dividido em vários fragmentos, que são transmitidos sequencialmente via diferentes canais. Cada réplica de cabeçalho tem duração (*Time on Air* - ToA) de $t_h = 233,472$ ms, enquanto cada fragmento de *payload* apresenta um ToA de $t_f = 102,4$ ms [19].

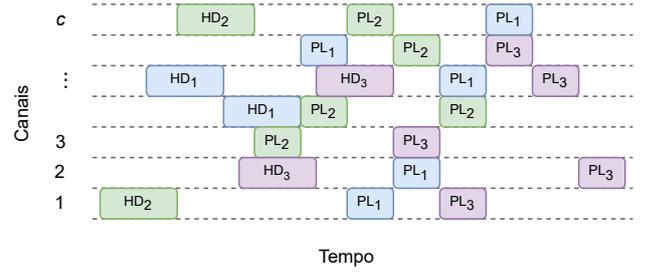


Fig. 1. Os dispositivos IoT transmitem pacotes LR-FHSS através de c canais no domínio da frequência. O subscrito em cada réplica do cabeçalho (HD_k) e fragmento de *payload* (PL_k) indica sua associação com o k -ésimo usuário.

A. Age-of-Information (AoI)

A AoI quantifica o quão atual é a informação que o *gateway* possui sobre o estado de um dispositivo IoT. A AoI instantânea do k -ésimo dispositivo é definida no tempo t como [20]

$$\Delta_k(t) = t - t_n^*, \quad (1)$$

em que t_n^* é o instante de geração do n -ésimo pacote mais recente do dispositivo k que foi recebido com sucesso pelo *gateway*.

Assim, a AoI $\Delta_k(t)$ aumenta linearmente ao longo do tempo enquanto nenhum novo pacote é recebido com sucesso. Por outro lado, quando o n -ésimo pacote é recebido com sucesso no instante t'_n , a AoI é reiniciada para $\Delta_k(t) = t'_n - t_n^*$ onde t_n^* é o instante de geração do pacote e t'_n é o instante em que o pacote é decodificado com sucesso pelo *gateway*. Essa reinicialização representa a atualização do pacote recebido.

A AoI média pode ser definida assintoticamente como [15]

$$\bar{\Delta}_k = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T \Delta_k(t) dt. \quad (2)$$

Uma forma de calcular (2) é por meio de métodos geométricos, decompondo $\Delta_k(t)$ em áreas trapezoidais Q_n , conforme ilustrado na região cinza da Figura 2. Cada área Q_n corresponde à contribuição do n -ésimo pacote para a AoI total, sendo calculada como [21]

$$Q_n = \underbrace{(t'_n - t'_{n-1})(t'_{n-1} - t_{n-1}^*)}_{\text{Área retangular}} + \underbrace{\frac{(t'_n - t'_{n-1})^2}{2}}_{\text{Área triangular}}, \quad (3)$$

em que t'_n e t'_{n-1} são os instantes de recepção dos pacotes n e $n-1$, respectivamente, e t_{n-1}^* é o instante de geração do pacote $n-1$. Para processos ergódicos e estacionários, a AoI média é obtida pela razão entre a soma das áreas Q_n e a soma dos intervalos $Y_n = t'_n - t'_{n-1}$ [15]:

$$\bar{\Delta}_k = \lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N Q_n}{\sum_{n=1}^N Y_n}, \quad (4)$$

sendo N o número total de pacotes recebidos com sucesso.

III. MODELO DE SISTEMA

Consideramos uma rede LR-FHSS composta por K dispositivos IoT que transmitem pacotes com *payload* de l bytes para um único *gateway*. A rede opera com c canais em cada

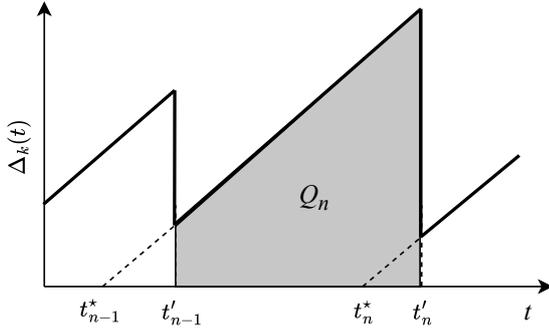


Fig. 2. Evolução da AoI com a região cinza demonstrando Q_n .

grid de frequência, sendo que o intervalo entre transmissões de pacotes segue uma distribuição exponencial $z \sim \text{Exp}(\lambda)$ com valor esperado $\mathbb{E}[z] = 1/\lambda$ [22].

Cada pacote transmitido consiste em h réplicas de cabeçalho e $f = \lceil (l + 3)/(6 \text{CR}) \rceil$ fragmentos de *payload*, onde CR denota a taxa de codificação enquanto o operador teto $\lceil \cdot \rceil$ garante requisitos inteiros de fragmentos. Esta estrutura garante transmissão robusta através da replicação de cabeçalho e fragmentação de *payload* adaptado ao esquema de codificação.

Ademais, o sistema emprega um modelo de canal onde todos os dispositivos estão dentro da área de cobertura do *gateway*, e os erros de decodificação são causados por colisões entre pacotes. Esta premissa é válida para redes com tráfego esparsos onde: *i*) as chegadas de pacotes seguem processos de Poisson independentes, e *ii*) os dispositivos mantêm taxas médias de transmissão constantes, de modo que o modelo considerado fornece uma aproximação razoável do comportamento do sistema, além de oferecer um equilíbrio ideal entre tratabilidade analítica e fidelidade ao desempenho do sistema real [10], [13], [23].

De acordo com [11], a probabilidade total de sucesso de um pacote LR-FHSS é dada por

$$P_s = P_h \cdot P_\mu, \quad (5)$$

em que P_h representa a probabilidade de sucesso no cabeçalho e P_μ a probabilidade de sucesso no *payload*. A probabilidade de sucesso no cabeçalho é dada por

$$P_h = 1 - \left[1 - \left(1 - \frac{1}{c} \right)^{A_h - 1} \right]^h \quad (6)$$

em que

$$A_h = \max \{ 1, 2\lambda_h t_h + \lambda_f (t_h + t_f) \}, \quad (7)$$

enquanto $\lambda_h = h \lambda K$ e $\lambda_f = f \lambda K$ denotam as taxas de transmissão de cabeçalhos e fragmentos, respectivamente. Por sua vez, o sucesso na decodificação do *payload* requer pelo menos $\mu = \lceil f \cdot \text{CR} \rceil$ fragmentos, de forma que P_μ é dada por

$$P_\mu = 1 - \sum_{i=0}^{\mu-1} \binom{f}{i} P_f^i (1 - P_f)^{f-i}, \quad (8)$$

em que

$$P_f = \left(1 - \frac{1}{c} \right)^{A_f - 1} \quad (9)$$

TABELA I
CONFIGURAÇÕES DO LoRaWAN.

LoRaWAN	-	DR9	-	DR8
Réplicas de Cabeçalho (h)	1	2	2	3
Taxa de Codificação (CR)	5/6	2/3	1/2	1/3

é a probabilidade de sucesso por fragmento de *payload*, e

$$A_f = \max (1, 2\lambda_f t_f + \lambda_h (t_h + t_f)) \quad (10)$$

caracteriza a janela de vulnerabilidade dos fragmentos. O coeficiente binomial $\binom{a}{b} = a!/(b!(a-b)!)$ determina as possibilidades combinatórias para recepção bem-sucedida de fragmentos.

A. Goodput

O desempenho da estratégia proposta é avaliado em termos de AoI e *goodput*. O *goodput*, denotado por \mathcal{G} , corresponde à taxa efetiva de transmissão de dados úteis na rede, representando o número médio de bytes recebidos com sucesso por segundo. Essa métrica é definida por

$$\mathcal{G} = P_s K \lambda l \quad [\text{bytes/s}]. \quad (11)$$

Esta definição considera que cada transmissão bem-sucedida contribui com l bytes para o *goodput* total do sistema, ponderado pela probabilidade de sucesso P_s e pela atividade agregada da rede ($K\lambda$).

IV. RESULTADOS NUMÉRICOS

Esta seção apresenta a análise quantitativa do desempenho do LR-FHSS, a partir das métricas de *goodput*, \mathcal{G} , e AoI. A avaliação foi realizada mediante um simulador de eventos discretos desenvolvido no *framework* SciPy em Python, cuja implementação detalhada está disponível em [18]. Em particular, consideramos o instante de recepção do pacote, para cálculo da AoI, como o momento em que o μ -ésimo fragmento do *payload* é decodificado corretamente no destino, após a recepção bem-sucedida de pelo menos uma das h réplicas de cabeçalho. Os parâmetros adotados, salvo indicação contrária, foram um intervalo médio entre transmissões $\lambda^{-1} = 900$ s, duração da simulação de 3600 s (1 hora), $c = 35$ canais e tamanho de pacote $l = 10$ bytes.

As configurações de transmissão analisadas, listadas na Tabela I, incluem parâmetros típicos de transceptores LR-FHSS [24] e, para comparação, as taxas de dados DR8 e DR9 do LoRaWAN para o cenário europeu, com largura de banda de canal de 137 kHz [19]. Ressalta-se que as configurações não padrão foram incluídas para explorar as relações entre redundância de cabeçalho e codificação.

Inicialmente, a Figura 3 ilustra o *goodput*, \mathcal{G} , em função do número de dispositivos, K , para as quatro configurações de cabeçalho e taxa de codificação da Tabela I. Nesta figura comparamos os valores simulados obtidos por meio do simulador implementado em [18] em comparação com os valores obtidos em (11). Observa-se uma boa concordância entre os resultados

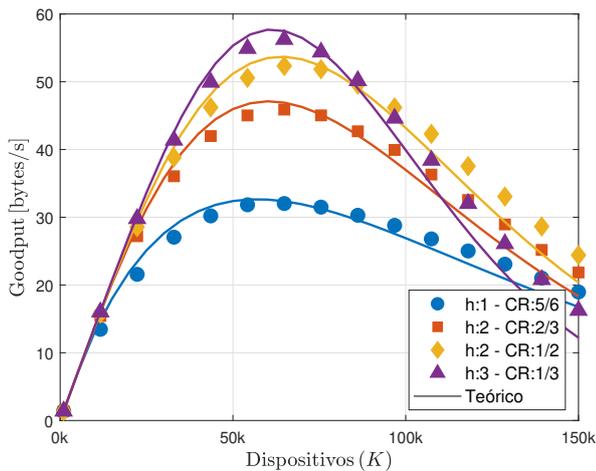


Fig. 3. *Goodput* em função do número de dispositivos, com as linhas contínuas representando o modelo teórico e os marcadores indicando os resultados simulados.

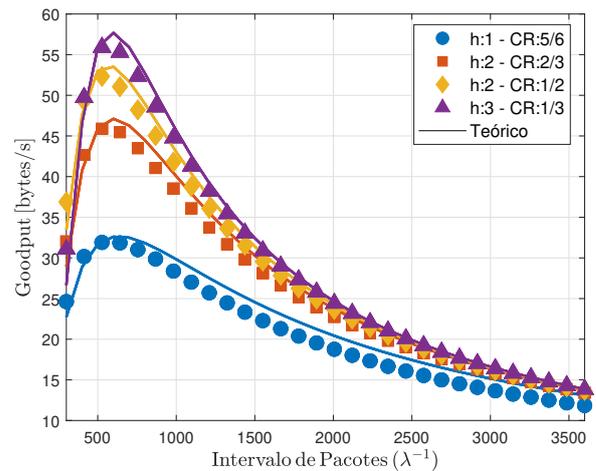


Fig. 5. Variação do *Goodput* com o intervalo médio de transmissão (λ^{-1}) para $K = 40000$.

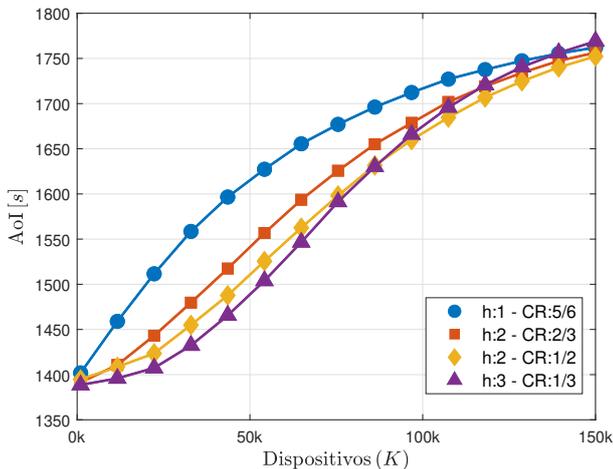


Fig. 4. AoI em função do número de dispositivos considerando as configurações apresentadas na Tabela I.

simulados e o modelo teórico em (11) realizado em [11], validando a simulação realizada. As pequenas discrepâncias decorrem da simplificação no cálculo de P_s , que desconsidera correlações e dependências entre réplicas de cabeçalho e fragmentos de *payload*. Com relação às diferentes configurações LoRaWAN implementadas, observa-se que a configuração $\{h : 3 - CR : 1/3\}$ atingiu o maior \mathcal{G} , evidenciando a importância da redundância de cabeçalho. Entretanto, para $K > 100$ mil, estratégias com menor redundância mostraram-se mais eficientes, com a configuração $\{h : 2 - CR : 1/2\}$ superando as demais. Cabe destacar que esta última configuração não é um DR padrão adotado para o LR-FHSS.

Complementarmente, a Figura 4 revela que a AoI média cresce com K . Este resultado implica que, em cenários com restrições de atualidade de informação (e.g., monitoramento industrial), a capacidade máxima suportada seria reduzida evidenciando a *trade-off* fundamental entre P_s e pontualidade da informação.

TABELA II
ÓTIMO λ^{-1} PARA FIGURAS 5 E 6.

Configuração	<i>Goodput</i>	AoI
{h:1 - CR:5/6}	575	2575
{h:2 - CR:2/3}	550	2350
{h:2 - CR:1/2}	600	2235
{h:3 - CR:1/3}	625	2235

Na sequência, as Figuras 5 e 6 analisam sistematicamente a influência do intervalo médio de transmissão (λ^{-1}) no desempenho do sistema para $K = 40$ mil dispositivos. Conforme ilustrado na Figura 5, valores reduzidos de λ^{-1} correspondem a intervalos mais curtos entre transmissões, elevando a probabilidade de colisões tanto de réplicas de cabeçalho quanto de fragmentos. Esse fenômeno reduz significativamente a probabilidade de sucesso P_s e, conseqüentemente, o *goodput* \mathcal{G} , além de aumentar a AoI média do sistema. À medida que λ^{-1} cresce, observa-se uma melhoria progressiva em \mathcal{G} até um ponto ótimo. Embora valores elevados de λ^{-1} minimizem as colisões, eles também reduzem excessivamente a frequência de transmissões, prejudicando o *goodput*. Em relação à AoI, a Figura 6 revela que o aumento de λ^{-1} promove uma redução da AoI média até um ponto ótimo que difere do ponto ótimo de *goodput*. Além disso, ao aumentar λ^{-1} além desse ponto, verifica-se um incremento na AoI devido ao maior espaçamento entre transmissões, o que impacta diretamente a AoI do sistema. Essa análise evidencia um *trade-off* crítico entre as métricas, uma vez que valores distintos de λ^{-1} permitem otimizar o sistema em relação à AoI ou ao *goodput*, conforme demonstrado na Tabela II. Assim, restrições operacionais em cenários práticos podem tornar a AoI um fator limitante para a maximização de \mathcal{G} , destacando a necessidade de equilíbrio entre esses parâmetros em projetos de sistemas IoT.

Desta forma, os resultados demonstram que otimizar apenas \mathcal{G} pode comprometer aplicações onde a atualidade da informação é crítica. Adicionalmente, configurações não padronizadas

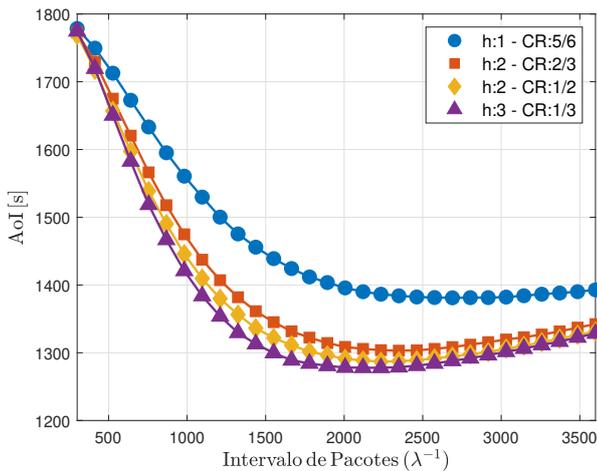


Fig. 6. Variação da AoI média com o intervalo médio de transmissão (λ^{-1}) para $K = 40000$.

apresentam ganhos potenciais em cenários densos. Por fim, o ponto ótimo de operação varia dependendo do caso de uso, sendo a AoI particularmente relevante em situações que demandam informação atualizada, estabelecendo assim limites para os parâmetros da rede.

V. CONCLUSÕES

Este estudo demonstrou o potencial do LR-FHSS para redes IoT densas e de longo alcance, destacando os compromissos fundamentais entre *goodput* e AoI. A análise quantitativa revelou cenários em que configurações com maior redundância de cabeçalho atingem o máximo *goodput*, enquanto estratégias com menor redundância tornam-se mais eficientes em cenários ultra-densos. Em acréscimo, demonstrou-se que o intervalo médio entre transmissões (λ^{-1}) apresenta pontos ótimos distintos para *goodput* e AoI, demonstrando que a otimização exclusiva do *goodput* pode comprometer aplicações sensíveis à atualidade da informação. Por fim, configurações não-padrão demonstraram potencial em cenários de alta densidade, sugerindo oportunidades para futuras investigações. Estes resultados estabelecem bases sobre a importância da otimização conjunta de métricas e desenvolvimento de protocolos em redes LR-FHSS, equilibrando confiabilidade, escalabilidade e atualidade da informação.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (307226/2021-2, 307222/2023-3 e 403124/2023-9). Em acréscimo, contou com o apoio da UTFPR por meio do Programa Institucional de Bolsas de Iniciação Científica (PIBIC).

REFERÊNCIAS

[1] A. Ikpehai, B. Adebisi, K. M. Rabie, K. Anoh, R. E. Ande, M. Ham-moudeh, H. Gacanin, and U. M. Mbanaso, “Low-Power Wide Area Network Technologies for Internet-of-Things: A Comparative Review,” *IEEE Internet of Things Journal*, vol. 6, no. 2, pp. 2225–2240, Apr. 2019.

[2] Statista, “Number of Internet of Things (IoT) connections worldwide from 2022 to 2023, with forecasts from 2024 to 2033,” 6 2024.

[3] 6G Flagship, “Key Drivers and Research Challenges for 6G Ubiquitous Wireless Intelligence,” University of Oulu, Tech. Rep. 6G Research Visions 1, Sep. 2019.

[4] U. Raza, P. Kulkarni, and M. Sooriyabandara, “Low Power Wide Area Networks: An Overview,” *IEEE Communications Surveys and Tutorials*, vol. 19, no. 2, pp. 855–873, Secondquarter 2017.

[5] *LoRaWAN™ 1.1 Specification*, LoRa Alliance, Inc., Oct. 2017, rev. 1.1. [Online]. Available: <https://resources.lora-alliance.org/technical-specifications/lorawan-specification-v1-1>

[6] O. B. A. Seller, “Wireless Communication Method,” U.S. Patent 9 647 718, May 09, 2017.

[7] Semtech Corp., *AN1200.64: LR-FHSS System Performance*, Oct. 2022, rev. 1.3. [Online]. Available: [semtech.com/products/wireless-rf/loraw-edge/lr1110#documentation](https://www.semtech.com/products/wireless-rf/loraw-edge/lr1110#documentation)

[8] G. Boquet, P. Tuset-Peiró, F. Adelantado, T. Watteyne, and X. Vilajosana, “LR-FHSS: Overview and Performance Analysis,” *IEEE Communications Magazine*, vol. 59, no. 3, pp. 30–36, 2021.

[9] G. Álvarez, J. A. Fraire, K. A. Hassan, S. Céspedes, and D. Pesch, “Uplink transmission policies for LoRa-based Direct-to-Satellite IoT,” *IEEE Access*, vol. 10, pp. 72 687–72 701, 2022.

[10] A. Maleki, H. H. Nguyen, and R. Barton, “Outage Probability Analysis of LR-FHSS in Satellite IoT Networks,” *IEEE Communications Letters*, vol. 27, no. 3, pp. 946–950, 2023.

[11] M. A. Ullah, K. Mikhaylov, and H. Alves, “Analysis and Simulation of LoRaWAN LR-FHSS for Direct-to-Satellite Scenario,” *IEEE Wireless Communications Letters*, vol. 11, no. 3, pp. 548–552, 2022.

[12] A. Maleki, E. Bedeer, and R. Barton, “Performance Evaluation and Low-Complexity Detection of the PHY Modulation of LR-FHSS Transmission in IoT Networks,” in *IEEE Vehicular Technology Conference (VTC2024-Spring)*, 2024, pp. 1–7.

[13] J. M. de Souza Sant’Ana, O. d. S. Neto, A. Hoeller, J. L. Rebelatto, R. D. Souza, and H. Alves, “Asynchronous Contention Resolution-Aided ALOHA in LR-FHSS Networks,” *IEEE Internet of Things Journal*, vol. 11, no. 9, pp. 16 684–16 692, 2024.

[14] E. Testi and E. Paolini, “Packet Collision Probability of Direct-to-Satellite IoT Systems,” *IEEE Internet of Things Journal*, vol. 12, no. 2, pp. 1843–1855, 2025.

[15] R. D. Yates, Y. Sun, D. R. Brown, S. K. Kaul, E. Modiano, and S. Ulukus, “Age of Information: An Introduction and Survey,” *IEEE Journal on Selected Areas in Communications*, vol. 39, no. 5, pp. 1183–1210, 2021.

[16] T. Song and Y. Kyung, “Deep Reinforcement Learning Based Age-of-Information-Aware Low-Power Active Queue Management for IoT Sensor Networks,” *IEEE Internet of Things Journal*, pp. 1–1, 2024.

[17] Y. Xiao, Q. Du, and G. K. Karagiannidis, “Statistical age of information: A risk-aware metric and its applications in status updates,” *IEEE Transactions on Wireless Communications*, vol. 24, no. 3, pp. 2325–2340, 2025.

[18] J. M. de Souza Sant’Ana, A. Hoeller, H. Alves, and R. D. Souza, “LR-FHSS-Sim: A Discrete-Event Simulator for LR-FHSS Networks,” in *Joint European Conference on Networks and Communications & 6G Summit*, 2024, pp. 700–705.

[19] *LoRa Alliance Technical Committee Regional Parameters Workgroup, Version 1.0.4 and Regional Parameters RP002*, LoRa Alliance, Sept. 2022. [Online]. Available: <https://resources.lora-alliance.org/technical-specifications/rp002-1-0-4-regional-parameters>

[20] S. Kaul, R. Yates, and M. Gruteser, “Real-time status: How often should one update?” in *Proceedings IEEE INFOCOM*, 2012, pp. 2731–2735.

[21] Z. Ding, R. Schober, and H. V. Poor, “Impact of NOMA on Age of Information: A Grant-Free Transmission Perspective,” *IEEE Transactions on Wireless Communications*, vol. 23, no. 5, pp. 3975–3989, 2024.

[22] K.-R. Koch, *Introduction to Bayesian statistics*, 2nd ed. Berlin, Germany: Springer, Jul. 2007.

[23] A. Maleki, H. H. Nguyen, E. Bedeer, and R. Barton, “Outage Probability Analysis of LR-FHSS and D2D-Aided LR-FHSS Protocols in Shadowed-Rice Fading Direct-to-Satellite IoT Networks,” *IEEE Internet of Things Journal*, vol. 11, no. 6, pp. 11 101–11 116, 2024.

[24] *LR1121 Transceiver - User Manual*, Semtech Corp., 2023, Rev. 2.0. [Online]. Available: <https://www.semtech.com/products/wireless-rf/loraw-connect/lr1121#documentation>