

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**LEONARDO PACHECO DE AGUIAR**

**ANÁLISE DE DESEMPENHO DE NOMA BASEADO EM  
Q-LEARNING EM REDES DE RETRANSMISSÃO  
SATÉLITE-TERRESTRE**

**CURITIBA  
2025**

# **LEONARDO PACHECO DE AGUIAR**

## **ANÁLISE DE DESEMPENHO DE NOMA BASEADO EM Q-LEARNING EM REDES DE RETRANSMISSÃO SATÉLITE-TERRESTRE**

**Performance Analysis of Q-Learning-Based NOMA in Satellite-Terrestrial Relay Networks**

Dissertação por coletânea apresentada como requisito para obtenção do título de “Mestre em Engenharia Elétrica” do Programa de Pós-Graduação em Sistemas de Energia (PPGSE) da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. Guilherme de Santi Peron

Coorientador: Prof. Dr. Marcos Eduardo Pivaro Monteiro

**CURITIBA  
2025**



4.0 Internacional

Esta licença permite download e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



---

LEONARDO PACHECO DE AGUIAR

**ANÁLISE DE DESEMPENHO DE NOMA BASEADO EM Q-LEARNING EM REDES DE RETRANSMISSÃO  
SATÉLITE-TERRESTRE**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Automação E Sistemas De Energia.

Data de aprovação: 26 de Junho de 2025

Dr. Guilherme De Santi Peron, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Andre Augusto Mariano, Doutorado - Universidade Federal do Paraná (Ufpr)

Dr. Joao Luiz Rebelatto, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 26/06/2025.

## AGRADECIMENTOS

Agradeço imensamente ao meu orientador, **Guilherme**, e ao meu coorientador, **Marcos**, pela orientação segura, pela paciência em todas as etapas do mestrado e pela confiança que sempre depositaram em mim. A atenção e o apoio de ambos foram fundamentais para enfrentar os desafios e amadurecer academicamente ao longo desta jornada.

Meu agradecimento também ao Professor **Jamil**, pela serenidade com que lidou com as dificuldades que surgiram e pela colaboração constante no processo de organização dos dados e nas simulações realizadas. Sua experiência e apoio técnico foram extremamente importantes para a condução da pesquisa.

Sou grato aos meus familiares, especialmente a **Luciano, Maria Célia** e **Leandro**, pelo amor e carinho. O apoio de vocês foi essencial para que eu tivesse a base necessária para seguir com a construção da minha formação.

À minha esposa, **Larissa**, meu reconhecimento e carinho especiais. Sua presença foi fundamental para minha decisão de iniciar essa caminhada acadêmica. Agradeço pelos conselhos, pelas palavras de incentivo e pelo amor constante, que me deram força nos momentos mais exigentes desta trajetória.

Muito obrigado!

## RESUMO

Aguiar, Leonardo Pacheco de. **Análise de desempenho de NOMA baseado em Q-Learning em redes de retransmissão satélite-terrestre.** 2025. 46 f. Dissertação por coletânea (Mestrado em Sistemas de Energia) – Universidade Tecnológica Federal do Paraná, Curitiba, 2025.

Neste trabalho, é analisado o desempenho do Acesso Múltiplo Não-Ortogonal (NOMA) baseado em *Q-learning* em Redes de Retransmissão Satélite-Terrestre (STRNs), abordando os principais desafios nas comunicações de Internet das Coisas (IoT) em larga escala. Especificamente, focou-se nas métricas de eficiência energética e de taxa de transmissão de dados normalizada em cenários de *uplink*. Integrando um algoritmo distribuído de *Q-learning* com o NOMA, os dispositivos IoT podem otimizar de forma autônoma os parâmetros de transmissão, como intervalos de tempo, canais e níveis de potência, aprimorando o desempenho geral da rede. O esquema proposto supera as estratégias de potência fixa, alcançando maior taxa de transmissão de dados normalizada e eficiência energética sob diferentes densidades de rede, oferecendo uma melhoria de até 73% na eficiência energética. Os resultados da simulação validam a eficácia do protocolo, demonstrando seu potencial para implementações em larga escala de IoT em STRNs, por meio de alocação eficiente de potência e redução das taxas de colisão.

Palavras-chave: Internet das Coisas, Q-Learning, Acesso Múltiplo Não-Ortogonal, Inteligência Artificial

() Não autorizo a disponibilização de endereço de correio eletrônico para contato.

() Autorizo a disponibilização do seguinte correio eletrônico para contato:  
leonardoaguiar@alunos.utfpr.edu.br

## ABSTRACT

Aguiar, Leonardo Pacheco de. **Performance Analysis of Q-Learning-Based NOMA in Satellite-Terrestrial Relay Networks.** 2025. 46 f. Dissertação por coletânea (Mestrado em Sistemas de Energia) – Universidade Tecnológica Federal do Paraná, Curitiba, 2025. Título original: Análise de desempenho de NOMA baseado em Q-Learning em redes de retransmissão satélite-terrestre

In this work, we analyze the performance of *Q*-learning-based Non-Orthogonal Multiple Access (NOMA) in Satellite-Terrestrial Relay Networks (STRNs), addressing key challenges in massive Internet of Things (IoT) communications. Specifically, we focus on energy efficiency and normalized throughput metrics in uplink scenarios. By integrating a distributed *Q*-learning algorithm with NOMA, IoT devices can autonomously optimize transmission parameters — such as time slots, channels, and power levels — enhancing overall network performance. The proposed scheme outperforms fixed-power strategies by achieving higher normalized throughput and energy efficiency under varying network densities, offering up to 73% improvement in energy efficiency. Simulation results validate the protocol's effectiveness, demonstrating its potential for large-scale IoT deployments in STRNs through efficient power allocation and reduced collision rates.

Keywords: Internet of Things, Q-Learning, Non-Orthogonal Multiple Access, Artificial Intelligence

## **LISTA DE FIGURAS**

**Figura 1 – Modelo do sistema ..... 16**

## LISTA DE SIGLAS

AoI	Idade da Informação, do inglês <i>Age of Information</i>
BER	Taxa de Erro de Bit, do inglês <i>Bit Error Rate</i>
CSI	Informação de Estado de Canal, do inglês <i>Channel State Information</i>
GF	Transmissão sem Permissão Prévia, do inglês <i>Grant-Free</i>
HSTRN	Rede de Retransmissão Híbrida Satélite Terrestre, do inglês <i>Hybrid Satellite-Terrestrial Relay Network</i>
ICRA	Abordagem de Roteamento Inteligente por Clusterização, do inglês <i>Intelligent Clustering Routing Approach</i>
IoT	Internet das Coisas, do inglês <i>Internet of Things</i>
KKT	Karush-Kuhn-Tucker
LEO	Órbita Terrestre Baixa, do inglês <i>Low Earth Orbit</i>
NOMA	Acesso Múltiplo Não-Ortogonal, do inglês <i>Non-Orthogonal Multiple Access</i>
RF	Rádio Frequência
SIC	Cancelamento Sucessivo de Interferência, do inglês <i>Successive Interference Cancellation</i>
SINR	Razão Sinal-Ruído Mais Interferência, do inglês <i>Signal-to-Interference-plus-Noise Ratio</i>
SNR	Relação Sinal-Ruído, do inglês <i>Signal-to-Noise Ratio</i>
STRN	Rede de Retransmissão Satélite-Terrestre, do inglês <i>Satellite-Terrestrial Relay Network</i>
UAV	Veículo Áereo Não-Tripulado, do inglês <i>Unmanned Aerial Vehicle</i>
URLLC	Comunicação Ultraconfiável de Baixa Latência, do inglês <i>Ultra Reliable Low Latency Communication</i>
VANETs	Redes Veiculares Ad-Hoc, do inglês <i>Vehicular Ad Hoc Networks</i>

## LISTA DE SÍMBOLOS

$D$	Quantidade de dispositivos
$R$	Raio de transmissão
$R$	Quantidade de repetidores
$F$	<i>Frames</i>
$T$	Quantidade de intervalos de Tempo
$d$	Dispositivo IoT
$t$	Intervalo de tempo
$c$	Canal
$C$	Quantidade de canais
$K$	Quantidade de níveis potências
$r$	Repetidor
$P_k$	Potência de transmissão selecionada
$x_d$	Sinal transmitido
$h_{d,r}$	Coeficiente do canal
$n_r$	Ruído Gaussiano
$N_0$	Densidade de potência espectral unilateral
$B$	Largura de banda
$N_f$	Figura de ruído
$K_{d,r}$	Perda de caminho
$d_{d,r}$	Distância entre o $d$ -ésimo e $r$ -ésimo
$\beta$	Taxa alvo em bps/Hz
$\delta_s$	Quantidade de mensagens corretamente decodificadas
$\mu_{\text{dist}}$	Quantidade média de mensagens distintas corretamente decodificadas
$\mu_{\text{total}}$	Quantidade total de mensagens decodificadas
$P_{\text{tx}}$	Potência de transmissão
$P_{\text{rx}}$	Potência de recepção
$\zeta$	Eficácia energética
$S$	Conjunto de estados
$A$	Quantidade ações que um agente pode executar
$\gamma$	Fator de desconto
$\alpha$	Taxa de aprendizado
$e$	Função recompensa

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>10</b>
<b>1.1</b>	<b>Motivação .....</b>	<b>13</b>
<b>1.2</b>	<b>Objetivos .....</b>	<b>13</b>
1.2.1	Objetivo Geral .....	13
1.2.2	Objetivos Específicos .....	14
1.2.3	Estrutura do Documento .....	15
<b>2</b>	<b>MODELO DO SISTEMA .....</b>	<b>16</b>
<b>2.1</b>	<b>Métricas do Sistema .....</b>	<b>18</b>
2.1.1	Taxa de transmissão Normalizada .....	18
2.1.2	Eficiência Energética .....	18
<b>2.2</b>	<b>Protocolo Proposto .....</b>	<b>19</b>
2.2.1	Proposta de Método de Alocação baseado em <i>Q-Learning</i> .....	19
<b>2.3</b>	<b>Aspectos Práticos .....</b>	<b>21</b>
<b>3</b>	<b>CONCLUSÃO .....</b>	<b>23</b>
	<b>REFERÊNCIAS .....</b>	<b>24</b>
	<b>Anexo A – ARTIGO PUBLICADO .....</b>	<b>26</b>
	<b>Anexo B – POLÍTICA DE DIREITOS AUTORAIS DO PERIÓDICO .....</b>	<b>33</b>

## 1 INTRODUÇÃO

A Internet das Coisas (em inglês *Internet of Things*, IoT) constitui uma tecnologia transformadora que permite a comunicação entre uma ampla gama de dispositivos. Sua rápida adoção no cotidiano tem sido impulsionada pela crescente disponibilidade de produtos e serviços inteligentes, voltados à automação e à conectividade em diversas áreas de aplicação (MENEGHELLO et al., 2019). Os casos de uso da IoT podem ser classificados, de forma geral, em dois grandes domínios. O primeiro refere-se à IoT crítica, que demanda altas taxas de transmissão por dispositivo e requer uma comunicação ultra confiável com baixa latência (em inglês *Ultra Reliable Low Latency Communication*, URLLC). O segundo tipo diz respeito à IoT massiva, caracterizada por um elevado número de dispositivos com baixo consumo de energia, baixo custo e baixa taxa de dados de transmissão.

Um dos principais desafios para a comunicação da IoT massiva é a limitada capacidade de transmissão a longas distâncias (BARICK; SINGHAL, 2022). Neste contexto, satélites de baixa órbita terrestre (em inglês *Low Earth Orbit*, LEO) surgem como uma solução promissora, oferecendo menor latência em comparação com satélites de órbitas mais elevadas. Devido à sua proximidade com a superfície terrestre, satélites LEO proporcionam maior eficiência na conectividade de áreas remotas, ao mesmo tempo em que reduzem as perdas por percurso, permitindo o uso de níveis de potência mais baixos nos transmissores. Isso resulta em menor consumo energético e melhor desempenho geral da rede (YUE et al., 2023). No entanto, a capacidade de *uplink* dos dispositivos IoT costuma ser severamente limitada pela potência de transmissão, o que inviabiliza, na maioria dos casos, a comunicação direta com os satélites LEO. Para superar esta restrição, empregam-se estações terrestres atuando como repetidoras, formando o que se denomina rede de retransmissão satélite-terrestre (em inglês *Satellite-Terrestrial Relay Network*, STRN) (GUO et al., 2019). Uma evolução desta arquitetura é a rede híbrida de retransmissão satélite-terrestre (em inglês *Hybrid Satellite-Terrestrial Relay Network*, HSTRN), a qual integra segmentos espaciais e terrestres com o objetivo de otimizar as taxas de transmissão, reduzir a degradação do sinal e ampliar a cobertura em regiões com conectividade limitada (GUO et al., 2022).

Diversos estudos têm explorado redes STRN e HSTRN com o objetivo de aprimorar seu desempenho em cenários de comunicação avançada (ZHAO et al., 2023), (ZHAO et al., 2021) e (AN; LIANG, 2019). Em (ZHAO et al., 2023), é proposto um

esquema STRN, que divide a comunicação em duas fases distintas: detecção e acesso aleatório. Essa abordagem contribui para a redução de interferências e possibilita a otimização dinâmica da eficiência de transmissão. O impacto de obstáculos e efeitos de sombreamento em redes HSTRN é discutido em (ZHAO et al., 2021), em que os autores introduzem um mecanismo de escalonamento baseado na relação sinal-ruído (em inglês *Signal-to-Noise Ratio*, SNR), visando à melhoria da taxa de erro de bit (em inglês *Bit Error Rate*, BER). Por sua vez, o estudo apresentado em (AN; LIANG, 2019) investiga um modelo híbrido HSTRN que utiliza repetidores terrestres para reduzir a degradação do sinal, promovendo maior cobertura, redução de latência, e, consequentemente, melhor eficiência geral da rede.

Uma preocupação adicional nos cenários de IoT massivo é a estratégia de acesso ao meio e a escassez de recursos para garantir a conexão massiva. O esquema de Transmissão sem Permissão Prévia (em inglês *Grant-Free*, GF), quando integrado ao Acesso Múltiplo Não-Ortogonal (em inglês *Non-Orthogonal Multiple Access*, NOMA), surge como uma solução promissora para mitigar esses desafios. Esta abordagem permite que os dispositivos transmitam dados diretamente sem a necessidade de um processo prévio de *handshaking*, reduzindo o congestionamento de dados e melhorando o acesso aleatório ao meio (LIU et al., 2021). O NOMA, por sua vez, oferece suporte adicional a redes de IoT massivo, ao permitir que múltiplos usuários compartilhem os mesmos recursos de forma eficiente. Isso é viabilizado por meio da alocação de diferentes níveis de potência aos usuários, otimizando simultaneamente a eficiência espectral e a eficiência energética (EMIR et al., 2021).

A alocação eficiente de recursos em redes heterogêneas pode ser significativamente aprimorada por meio da aplicação de técnicas de aprendizado de máquina. Em (TUBIANA et al., 2022), os autores investigam a integração do NOMA com o algoritmo de *Q-Learning* em redes STRN, com o objetivo de otimizar dinamicamente as probabilidades de acesso ao meio e a estratégia de retransmissão. Esta abordagem resulta em melhorias na taxa de transmissão de dados e na redução da latência em cenários de IoT massiva. Em (GUO et al., 2020), é apresentado o modelo TROVE, voltado a redes *Ad Hoc* veiculares (em inglês *Vehicular Ad Hoc Networks*, VANETs), que utiliza aprendizado por reforço para avaliar, em tempo real, a segurança e a eficiência das comunicações entre veículos. Considerando a alta mobilidade e a natureza dinâmica das redes, o TROVE incorpora variáveis contextuais como geolocalização, condições de rede, densidade de nós e clima, oferecendo um gerenciamento de confiança adaptativo.

A influência de algoritmos de aprendizado de máquina supervisionados e não supervisionados na otimização de redes IoT com suporte via satélite é explorada em (ZHOU et al., 2021). O sistema proposto realiza a distribuição equitativa de recursos de rede entre os dispositivos remotos, adaptando-se às demandas individuais de comunicação de tempo real, com foco na eficiência e escalabilidade. Em (ZHAO et al., 2022), é proposta uma estratégia descentralizada de clusterização NOMA baseada em *Q-Learning*, na qual os dispositivos IoT são agrupados de acordo com a otimização da potência de transmissão selecionada. Esta é determinada por algoritmos baseados nas condições de *Karush-Kuhn-Tucker* (KKT), permitindo um balanceamento eficiente entre desempenho e consumo energético. Para reduzir a complexidade computacional, os cálculos são realizados de forma *offline* pelos repetidores, com cada *cluster* utilizando canais distintos para minimizar interferências. Por fim, o estudo apresentado em (GUO et al., 2023) introduz a abordagem Abordagem de Roteamento Inteligente por Clusterização (em inglês *Intelligent Clustering Routing Approach*, ICRA), que adota uma estratégia inteligente de clusterização descentralizada voltada a redes de veículos aéreos não tripulados (em inglês *Unmanned Aerial Vehicle*, UAV). Devido à alta mobilidade e aos recursos computacionais limitados destes dispositivos, o ICRA define, em cada *cluster*, um nó líder responsável pelo gerenciamento das comunicações, reduzindo o congestionamento, o consumo energético e o número de falhas.

Com base nos estudos discutidos na literatura acima, este trabalho propõe a aplicação do algoritmo de *Q-Learning* para a otimização do acesso aleatório ao meio em redes STRN voltadas para dispositivos IoT. A estratégia adotada segue um modelo descentralizado, no qual cada dispositivo mantém e gerencia sua própria tabela *Q*, com base em informações de retorno, do inglês *feedback*, fornecidas pelos repetidores. Este retorno consiste em um único bit, indicando se a tentativa de transmissão foi bem-sucedida ou resultou em falha. Além disto, o esquema incorpora o cancelamento sucessivo de interferência (em inglês *Successive Interference Cancellation*, SIC) em conjunto com o NOMA, permitindo que múltiplos dispositivos compartilhem simultaneamente o mesmo canal por meio da alocação diferenciada de níveis de potência de transmissão. Diferentemente de abordagens anteriores, como a de (TUBIANA et al., 2022), que assume um nível fixo de potência, ou de (GUO et al., 2020; GUO et al., 2023), que exploram técnicas de aprendizado de máquina aplicadas ao gerenciamento de confiança e à clusterização, respectivamente, este trabalho aprimora a abordagem do *Q-Learning* ao integrar mecanismos de alocação dinâmica de potência. Esta integração permite estratégias adaptativas de transmissão, resultando em melhorias tanto na eficiência

espectral quanto na escalabilidade de redes STRN aplicadas à IoT massiva. Além disto, a metodologia proposta avalia não apenas a taxa de transmissão de dados, mas também a eficiência energética como métrica central de desempenho. Os resultados obtidos demonstram que o algoritmo empregado melhora significativamente a taxa de sucesso na transmissão e permite que os repetidores determinem os níveis ideais de potência, otimizando o consumo energético e aprimorando a eficiência energética da rede.

## 1.1 Motivação

A motivação para este trabalho está fundamentada nos diversos desafios impostos pela evolução das redes de comunicação, com ênfase no contexto do IoT. Em redes IoT massivas, é comum a ocorrência de restrições severas de recursos, como a disponibilidade limitada de energia, a elevada probabilidade de colisões entre transmissões simultâneas e a escassez de receptores dedicados. Neste contexto, soluções baseadas em redes STRN têm se destacado como alternativas promissoras, especialmente em regiões remotas, em que a integração entre satélites LEO e nós repetidores possibilita a entrega eficiente de tráfego de dados.

Para reduzir as limitações de recursos, a utilização do NOMA permite o compartilhamento eficaz de recursos de canal entre múltiplos dispositivos, enquanto a técnica SIC possibilita que os repetidores sejam capazes de decodificar múltiplas transmissões simultâneas no mesmo canal e intervalo de tempo.

Este estudo baseia-se em abordagens consolidadas na literatura para desenvolver soluções aprimoradas voltadas à otimização de redes STRN. A introdução de estratégias de aprendizado de máquina visa elevar ainda mais o desempenho destas redes, promovendo ganhos em termos de tráfego de dados, taxa de transmissão normalizada e eficiência energética. Como impacto direto, busca-se estender a extensão da vida útil das baterias dos dispositivos IoT, fator essencial para garantir a sustentabilidade operacional dessas redes em longo prazo.

## 1.2 Objetivos

### 1.2.1 Objetivo Geral

Este trabalho segue o formato de coletânea de artigos científicos em virtude do artigo *Performance Analysis of Q-Learning-Based NOMA in SatelliteTerrestrial Relay*

*Networks*, publicado no periódico **Physical Communication** (DE AGUIAR et al., 2025). Este estudo teve como objetivo investigar a aplicação de técnicas de aprendizado de máquina em cenários de comunicação envolvendo dispositivos de IoT massiva, utilizando redes satelitais com retransmissão por estações terrestres. A arquitetura adotada baseia-se em uma rede STRN, na qual o acesso ao meio é realizado por meio do esquema GF, combinado com NOMA. Para a decodificação das transmissões simultâneas, os repetidores empregam a técnica SIC. A avaliação do desempenho do sistema proposto foi conduzida com base em duas métricas principais: a taxa de transmissão de dados e a eficiência energética, permitindo uma análise da viabilidade da solução em ambientes com restrições de recursos.

### 1.2.2 Objetivos Específicos

- Desenvolver um ambiente de simulação computacional com o objetivo de modelar e validar o desempenho da rede STRN proposta;
- Estabelecer as métricas de avaliação de desempenho que serão utilizadas no estudo, com ênfase na análise da taxa de transmissão de dados e da eficiência energética da rede;
- Definir os níveis de potência de transmissão a serem adotados pelos dispositivos, considerando as limitações energéticas e a viabilidade física do sistema;
- Configurar os principais parâmetros do algoritmo de aprendizado por reforço *Q-Learning* — tais como a taxa de aprendizagem, o fator de desconto e a estratégia de exploração — de modo a garantir a convergência eficiente da política de decisão adotada pelos dispositivos;
- Conduzir simulações sob diferentes configurações de recursos de rede, variando aspectos como o número de dispositivos, a quantidade de canais disponíveis e os esquemas de alocação de potência, a fim de avaliar a escalabilidade e a robustez do sistema proposto.
- Comparar os resultados obtidos com os de modelos e abordagens consolidadas na literatura, de forma a demonstrar as vantagens, melhorias de desempenho e possíveis limitações da solução proposta.

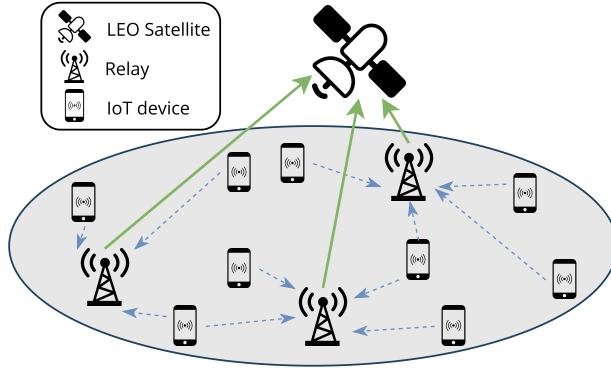
### 1.2.3 Estrutura do Documento

Por se tratar de uma defesa por coletânea de artigos, este documento segue uma estrutura mais sucinta. O Capítulo 1 apresenta uma introdução ao tema das redes STRN, abordando a arquitetura proposta e contextualizando as principais abordagens utilizadas pela comunidade científica para lidar com desafios semelhantes. O Capítulo 2 descreve em linhas gerais o funcionamento do sistema proposto, incluindo as métricas adotadas para avaliação de desempenho e a definição do protocolo de comunicação desenvolvido. No Capítulo 3, são discutidas as conclusões obtidas a partir do estudo. Por fim, o Anexo A apresenta, na íntegra, o artigo publicado no periódico **Physical Communication** (DE AGUIAR et al., 2025), enquanto o Anexo B apresenta a política de *copyright* do periódico em questão.

## 2 MODELO DO SISTEMA

O cenário considerado contém  $\mathcal{D}$  dispositivos IoT distribuídos em uma área de raio  $\mathcal{R}$ , comunicando-se com  $R$  nós terrestres repetidores, como ilustrado na Figura 1. Os nós repetidores desempenham um papel fundamental na transmissão dos dados para os satélites LEO. Esta suposição se baseia em cenários práticos, em que a comunicação direta entre dispositivos IoT e satélites é impraticável devido às restrições de potência e recursos computacionais (LIU et al., 2021; ZHAO et al., 2022).

**Figura 1 – O modelo do sistema consiste em  $\mathcal{D}$  dispositivos IoT distribuídos dentro de uma área circular de raio  $\mathcal{R}$ . Esses dispositivos são suportados por  $R$  nós de retransmissão, que estabelecem conectividade com um satélite LEO.**



**Fonte:** Extraída de (DE AGUIAR et al., 2025).

O acesso ao meio é provido por meio do modelo GF *slotted Aloha*, no qual  $F$  frames são divididos em  $T$  intervalos de tempo. Cada dispositivo  $d$ -ésimo IoT transmite no intervalo de tempo  $t \in [1, \dots, T]$ , selecionando um canal  $c \in [1, \dots, \mathcal{C}]$ . Além disso, é implementada uma estratégia SIC-NOMA, utilizando  $K$  níveis de potência de transmissão pré-definidos, permitindo que cada dispositivo IoT escolha um dos níveis de potência de transmissão em cada intervalo de tempo.

Consequentemente, o sinal recebido pelo repetidor  $r$ -ésimo oriundo do dispositivo IoT  $d$ -ésimo é expressado como

$$y_{d,r} = \sqrt{P_k k_{d,r}} h_{d,r} x_d + n_r, \quad (1)$$

onde  $P_k$  é a potência de transmissão selecionada pelo dispositivo IoT  $d$ -ésimo entre os  $K$  níveis de potência disponíveis,  $x_d$  é o sinal transmitido e  $h_{d,r}$  é o coeficiente do canal entre o dispositivo IoT  $d$ -ésimo e o repetidor terrestre  $r$ -ésimo, com magnitude

que segue a distribuição Nakagami- $m$ . Além disso,  $n_r$  representa o ruído Gaussiano aditivo (AWGN), com potência dada por  $N = N_0BN_f$ , onde  $N_0$  é a densidade de potência espectral unilateral,  $B$  é a largura de banda e  $N_f$  é a figura de ruído. Por fim, o parâmetro de perda de caminho  $K_{d,r}$ , seguindo o modelo descrito em (3GPP, 2017), é definido por

$$k_{d,r} = -128.1 - 37.6 \log_{10}(d_{d,r}), \quad (2)$$

em que  $d_{d,r}$  é distância entre o  $d$ -ésimo dispositivo IoT e  $r$ -ésimo repetidor terrestre.

Como a estratégia empregada é um NOMA assistido, os repetidores são capazes de decodificar transmissões oriundas de múltiplos dispositivos, compartilhando o mesmo intervalo de tempo e o mesmo canal, por meio da decodificação SIC. Quando múltiplas mensagens são recebidas simultaneamente, o processo de decodificação é iniciado pelo sinal com maior SNR, enquanto os outros sinais recebidos são inicialmente tratados como interferência. Após a decodificação do primeiro sinal, o próximo sinal com maior SNR será processado, tratando-se os demais sinais como ruído. Esse processo iterativo continua até que todas as mensagens sejam decodificadas corretamente ou até que o ruído se torne tão grande que os sinais não possam mais ser decodificados.

De acordo com a razão sinal-ruído mais interferência (em inglês *Signal-to-Interference-plus-Noise Ratio*, SINR) para o  $d$ -ésimo dispositivo e o  $r$ -ésimo repetidor, tem-se que

$$\text{SINR}_{(d,r)} = \frac{P_{k,d}|h_{d,r}|^2}{\sum_{l=d+1}^K P_{k,l}|h_{l,r}|^2 + N}. \quad (3)$$

Portanto, para a decodificação correta do sinal transmitido e recebido pelo nó repetidor, o SINR recebido deve ser maior que um limiar pré-definido, como:

$$\mathcal{O} = \Pr \left\{ \log_2(1 + \text{SINR}_{(d,r)}) \geq \beta \right\}, \quad (4)$$

onde  $\beta$  define a taxa alvo (em bps/Hz). O evento de *outage* de transmissão ocorre quando a transmissão cai abaixo do limiar do SINR, impedindo, assim, que o repetidor decodifique a mensagem recebida. Quando múltiplas mensagens são recebidas no mesmo *slot* de tempo, a Equação 4 é aplicada sequencialmente, iniciando pela mensagem com o maior SINR. Se uma mensagem for corretamente decodificada, a análise prossegue para a seguinte; caso contrário, todas as mensagens subsequentes com SINR inferior são consideradas não decodificadas.

## 2.1 Métricas do Sistema

Para avaliar o desempenho do sistema proposto, foram definidas duas métricas: a taxa de transmissão de dados normalizada e a eficiência energética.

### 2.1.1 Taxa de transmissão Normalizada

De acordo com (TUBIANA et al., 2022), a taxa de transmissão de dados é definida como uma métrica que qualifica a eficiência da utilização do quadro de transmissão pelos dispositivos IoT. Essa métrica é expressa como

$$\tau = \frac{\beta}{\mathcal{C}} \cdot \frac{\delta_s}{T} \cdot \frac{\mu_{\text{dist}}}{\mu_{\text{total}}} \quad [\text{bps/Hz}], \quad (5)$$

em que  $\delta_s$  é a média do número de mensagens corretamente decodificadas transmitidas pelos dispositivos IoT. Além disso,  $\mu_{\text{dist}}$  representa a média de mensagens distintas corretamente decodificadas recebidas pelo satélite a partir de dispositivos IoT em cada quadro, enquanto que  $\mu_{\text{total}}$  é o número total de mensagens corretamente decodificadas e recebidas pelo satélite em cada quadro.

### 2.1.2 Eficiência Energética

O sistema também foi avaliado utilizando a métrica de eficiência energética, definida como a divisão do número de mensagens distintas corretamente recebidas pelo consumo total associado a essas transmissões sobre o quadro. A métrica da eficiência energética é expressa por

$$\eta = \frac{\mu_{\text{dist}}}{P_{\text{total}}} \quad [\text{msg/W}], \quad (6)$$

onde

$$P_{\text{total}} = \frac{1}{\zeta} \sum_{k=1}^K P_k \delta_k + \mathcal{D} (P_{\text{TX}} + P_{\text{RX}}). \quad (7)$$

O termo  $\sum_{k=1}^K P_k \delta_k$  representa a média total da potência de transmissão utilizada por todos os usuários, onde  $P_k$  é o nível de potência associado ao  $k$ -ésimo usuário na estratégia SIC-NOMA e  $\delta_k$  denota a média do número de usuários que selecionam este nível de potência durante o quadro, com  $\sum_{k=1}^K \delta_k = \mathcal{D}$ . Além disso, os parâmetros  $P_{\text{tx}}$  e  $P_{\text{rx}}$  representam a potência de consumo fixa de transmissão e recepção, devido aos circuitos RF dos dispositivos IoT, respectivamente, enquanto  $\zeta$  representa a eficiência energética do amplificador de potência.

## 2.2 Protocolo Proposto

No protocolo proposto, denominado de QL-MP-NOMA, exploram-se os benefícios do aprendizado por reforço distribuído por meio do algoritmo *Q-Learning*, permitindo que cada dispositivo IoT selecione de forma autônoma a alocação ideal de parâmetros para o acesso ao meio sem fio. O método do *Q-Learning* é um algoritmo de aprendizagem de máquina baseado no paradigma de agente-estado-ação. Sua operação se fundamenta no uso de uma tabela  $Q$  com dimensões  $S \times A$ , em que  $S$  representa o conjunto de estados possíveis que o agente pode ocupar, e  $A$  corresponde às ações disponíveis que o agente pode executar em cada estado. Desta forma, o algoritmo opera sobre um espaço finito de estados e ações, registrando em sua tabela  $Q$  os valores de recompensa esperada associados a cada par  $(S_i, A_i)$ . No contexto da rede STRN, cada dispositivo IoT mantém e atualiza sua própria tabela  $Q$  de forma independente. Em cada intervalo de tempo, um agente  $i$ , ao encontrar-se em um determinado estado  $S_i$ , seleciona uma ação  $A_i$  com o objetivo de maximizar a recompensa acumulada ao longo do tempo. A atualização da tabela  $Q$  é realizada de acordo com a seguinte expressão:

$$Q(S_i, A_i) \leftarrow (1 - \alpha) Q(S_i, A_i) + \alpha \left[ \epsilon + \gamma \max_a Q(S_{i+1}, a) \right], \quad (8)$$

onde  $\gamma$  é o fator de desconto e  $\alpha$  é a taxa de aprendizado. O parâmetro  $\gamma$  regula o balanceamento entre a importância das recompensas futuras e imediatas. Especificamente, quando  $\gamma$  utilizado é igual a 1, o sistema priorizará as recompensas a longo prazo, fomentando estratégias com ganhos futuros. Já, para valores baixos de  $\gamma$ , o sistema exerce grande importância nas recompensas imediatas, priorizando a otimização de curto prazo. Por outro lado, o parâmetro  $\alpha$  influencia a taxa de aprendizado do sistema. Quanto mais próximo de 1, mais rápido é o aprendizado, porém pode tornar o sistema instável, fazendo com que o sistema reaja de forma brusca às mudanças recentes. De uma forma mais conservadora, valores baixos de  $\alpha$  fazem com que o processo de aprendizado seja mais lento, porém tornam o sistema menos sensível a variações ocasionais. A contínua atualização da tabela  $Q$  permite que o agente aprenda e otimize suas ações ao longo do tempo, através de ajustes com decisões baseadas nas recompensas recebidas e recompensas futuras estimadas (SPANÒ et al., 2019). A função de recompensa,  $e$ , é igual a 1 para mensagens corretamente decodificadas, e -1 para mensagens não decodificadas.

### 2.2.1 Proposta de Método de Alocação baseado em *Q-Learning*

A operação do esquema proposto, baseado no algoritmo *Q-Learning*, pressupõe que cada dispositivo mantenha e atualize sua própria tabela  $Q$  de forma independente. No

---

**Algorithm 1:** Método de Alocação Baseado em *Q-Learning*.

---

**Input:** Tabela  $Q$  inicializada com todas as posições com o valor zero

```

1 forall  $f \in [1, F]$  do
2   forall  $t \in [1, T]$  do
3     Dispositivo IoT define o intervalo de tempo  $t$ , canal  $c$  e nível de
      potencia  $P_k$  correspondente ao valor mais alto em sua tabela  $Q$  para
      a transmissão;
4     Os repetidores aplicam o SIC para decodificar possíveis mensagens
      sobrepostas transmitidas no mesmo canal e intervalo de tempo;
5     Os repetidores enviam em broadcast um único bit de retorno por
      intervalo de tempo, de acordo com  $\epsilon$ ;
6   end
7   forall  $i \in [1, \mathcal{D}]$  do
8     | O dispositivo IoT  $i$  atualiza sua própria tabela  $Q$  utilizando (8);
9   end
10 end
11 Os repetidores encaminham a mensagem decodificadas para os satélites;
```

---

início de cada quadro de transmissão, o dispositivo IoT seleciona a ação associada ao maior valor de recompensa estimada em sua respectiva  $Q$ . Essa ação determina os parâmetros de transmissão a serem utilizados, incluindo canal de comunicação, o intervalo de tempo e nível de potência de transmissão. Neste contexto, a tabela  $Q$  é estruturada por uma matriz tridimensional com as dimensões  $(\mathcal{C} \times T \times K)$ .

Uma vez que selecionados os parâmetros de transmissão, o dispositivo envia sua mensagem aos repetidores disponíveis que cobrem a respectiva área geográfica. Cada repetidor tenta decodificar os sinais recebidos utilizando o SIC. Após a conclusão de todas as transmissões dentro de um quadro serem completadas, os repetidores emitem, em modo *broadcast*, um bit de retorno para todos os dispositivos, indicando sucesso ou falha de suas respectivas transmissões. Com base neste retorno, cada dispositivo atualiza sua tabela  $Q$ , ajustando seus valores de recompensa estimada de acordo com o resultado obtido. Esse processo de realimentação e atualização permite o refinamento progressivo da política de decisão adotada por cada nó IoT. A cada novo quadro, os dispositivos tendem a selecionar combinações de tempo, canal e potência mais adequadas, otimizando progressivamente o desempenho da rede. A descrição formal do protocolo proposto encontra-se apresentada no Algoritmo 1.

### 2.3 Aspectos Práticos

Nesta subseção, são discutidas as principais considerações práticas associadas à implementação da abordagem proposta em cenários reais. A análise concentra-se em aspectos relacionados à memória, escalabilidade, complexidade computacional, com o objetivo de garantir a viabilidade operacional e o desempenho.

- **Memória:** O protocolo proposto adota uma abordagem distribuída, em que cada dispositivo IoT mantém e atualiza sua própria Tabela  $Q$ . Para isso, cada nó deve dispor de capacidade de armazenamento suficiente para manter uma matriz de dimensões  $(\mathcal{C} \times T \times K)$ , representando as escolhas de canal, intervalo de tempo e potência para comunicação.
- **Complexidade Computacional:** A atualização dos valores na tabela  $Q$  é realizada por meio de uma equação de primeira ordem, característica do algoritmo *Q-Learning*. Como resultado, a carga computacional de cada dispositivo permanece mínima, o que é particularmente adequado para atender aos requisitos rigorosos das redes IoT de grande escala.
- **Escalabilidade:** A arquitetura descentralizada do sistema permite que cada dispositivo otimize individualmente seus parâmetros de transmissão, dispensando a necessidade de coordenação centralizada. Além disso, como os repetidores transmitem retorno de um único bit por intervalo de tempo, sinalizando sucesso ou falha de transmissão, independentemente da quantidade de dispositivos de rede. Essa característica contribui para a escalabilidade do sistema, possibilitando sua operação eficiente mesmo com densidade crescente de dispositivos. No entanto, à medida que a população de dispositivos excede determinados limites, pode ser necessário expandir os recursos da rede, como a adição de canais ou de novos intervalos de tempo, para preservar o desempenho e evitar saturação.
- **Informação de Estado de Canal (CSI):** Um dos desafios do uso do SIC em canais NOMA reside na sensibilidade à precisão da estimativa da informação do estado de canal. Erros de estimativa podem comprometer a eficácia do processo de cancelamento sucessivo de interferência, introduzindo ruído residual e impactando negativamente a taxa de decodificação (GAO et al., 2018; GRYBOSI et al., 2022). Para reduzir este problema, propõe-se a inclusão de uma margem de segurança na definição dos níveis de potência. Essa margem pode ser adaptada com base na

variância esperada da estimativa de CSI, a fim de garantir robustez na decodificação e confiabilidade no desempenho do SIC.

### 3 CONCLUSÃO

Este trabalho apresenta uma abordagem distribuída baseada em *Q-Learning* para otimização do acesso aleatório ao meio em redes STRN, visando aplicações de IoT massiva, como o congestionamento de redes, ineficiência energética e a decodificação confiável. A proposta integra técnicas NOMA o SIC, além de alocação dinâmica de potência, permitindo que dispositivos IoT transmitam dados de forma eficiente, otimizando de forma dinâmica seus parâmetros de transmissão, como o intervalo de tempo, canal e nível de potência, reduzindo as colisões e se adaptando às condições da rede. Os resultados das simulações mostram que o sistema proposto teve um alto desempenho em comparação com estratégias de potência fixa, entregando uma maior taxa de transmissão de dados, melhorando a eficiência energética e aumentando o tempo de vida da bateria dos dispositivos IoT em cenários de alta densidade.

Como perspectivas para investigações futuras, destaca-se a adoção de políticas de acesso dependentes da idade da informação (em inglês *Age of Information*, AoI) visando a priorização dinâmica de dispositivos com informações mais desatualizadas, potencializando a equidade na renovação dos dados e a redução do AoI médio na rede como em (PEREIRA et al., 2025). Outra possibilidade de uma possível extensão consiste na consideração de perdas no enlace entre o satélite e os repetidores terrestres, modelado como um canal com apagamento. Essa abordagem permitiria representar de forma mais realista os efeitos de interferência, bloqueios, sombreamento e condições atmosféricas adversas que podem comprometer a entrega de pacotes. Neste caso, poderiam ser investigados mecanismos de retransmissões seletivas ou alocação adaptativa de potência e tempo para compensar as falhas de comunicação. Além disto, seria possível analisar o impacto do apagamento no desempenho global do sistema, especialmente na eficiência energética e na taxa de sucesso da aprendizagem.

## REFERÊNCIAS

3GPP. *Technical specification group radio access network; evolved universal terrestrial radio access (E-UTRA); further advancements for E-UTRA physical layer aspects (release 9)*. Sophia Antipolis, France, March 2017.

AN, K.; LIANG, T. Hybrid satellite-terrestrial relay networks with adaptive transmission. **IEEE Transactions on Vehicular Technology**, v. 68, n. 12, p. 12448–12452, 2019.

BARICK, S.; SINGHAL, C. Multi-UAV assisted IoT NOMA uplink communication system for disaster scenario. **IEEE Access**, v. 10, p. 34058–34068, 2022.

DE AGUIAR, L. P.; MONTEIRO, M. E. P.; FARHAT, J.; PERON, G. de S.; BRANTE, G. Performance analysis of q-learning-based noma in satellite–terrestrial relay networks. **Physical Communication**, v. 69, p. 102619, 2025. ISSN 1874-4907. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1874490725000229>.

EMIR, A.; KARA, F.; KAYA, H.; YANIKOMEROGLU, H. Deepmud: Multi-user detection for uplink grant-free noma iot networks via deep learning. **IEEE Wireless Communications Letters**, v. 10, n. 5, p. 1133–1137, 2021.

GAO, Y.; XIA, B.; LIU, Y.; YAO, Y.; XIAO, K.; LU, G. Analysis of the dynamic ordered decoding for uplink noma systems with imperfect csi. **IEEE Transactions on Vehicular Technology**, v. 67, n. 7, p. 6647–6651, 2018.

GRYBOSI, J. F.; REBELATTO, J. L.; MORITZ, G. L. Age of information of sic-aided massive iot networks with random access. **IEEE Internet of Things Journal**, v. 9, n. 1, p. 662–670, 2022.

GUO, J.; GAO, H.; LIU, Z.; HUANG, F.; ZHANG, J.; LI, X.; MA, J. Icra: An intelligent clustering routing approach for uav ad hoc networks. **IEEE Transactions on Intelligent Transportation Systems**, v. 24, n. 2, p. 2447–2460, 2023.

GUO, J.; LI, X.; LIU, Z.; MA, J.; YANG, C.; ZHANG, J.; WU, D. Trove: A context-awareness trust model for vanets using reinforcement learning. **IEEE Internet of Things Journal**, v. 7, n. 7, p. 6647–6662, 2020.

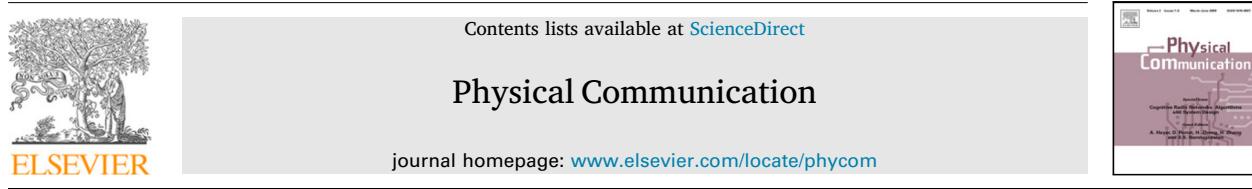
GUO, K.; AN, K.; ZHANG, B.; HUANG, Y.; GUO, D.; ZHENG, G.; CHATZINOTAS, S. On the performance of the uplink satellite multiterrestrial relay networks with hardware impairments and interference. **IEEE Systems Journal**, v. 13, n. 3, p. 2297–2308, 2019.

GUO, K.; DONG, C.; AN, K. Noma-based cognitive satellite terrestrial relay network: Secrecy performance under channel estimation errors and hardware impairments. **IEEE Internet of Things Journal**, v. 9, n. 18, p. 17334–17347, 2022.

LIU, J.; SHI, Z.; ZHANG, S.; KATO, N. Distributed q-learning aided uplink grant-free noma for massive machine-type communications. **IEEE Journal on Selected Areas in Communications**, v. 39, n. 7, p. 2029–2041, 2021.

- MENEGHELLO, F.; CALORE, M.; ZUCCHETTO, D.; POLESE, M.; ZANELLA, A. IoT: Internet of threats? A survey of practical security vulnerabilities in real IoT devices. **IEEE Internet of Things Journal**, v. 6, n. 5, p. 8182–8201, 2019.
- PEREIRA, F. M.; FARHAT, J. d. A.; REBELATTO, J. L.; BRANTE, G.; SOUZA, R. D. Reinforcement-learning-aided noma random access: An aoi-based timeliness perspective. **IEEE Internet of Things Journal**, v. 12, n. 5, p. 6058–6061, 2025.
- SPANÒ, S.; CARDARILLI, G. C.; NUNZIO, L. D.; FAZZOLARI, R.; GIARDINO, D.; MATTA, M.; NANNARELLI, A.; RE, M. An efficient hardware implementation of reinforcement learning: The  $q$ -learning algorithm. **IEEE Access**, v. 7, p. 186340–186351, 2019.
- TUBIANA, D. A.; FARHAT, J.; BRANTE, G.; SOUZA, R. D. Q-learning NOMA random access for IoT-satellite terrestrial relay networks. **IEEE Wireless Communications Letters**, v. 11, n. 8, p. 1619–1623, 2022.
- YUE, P.; AN, J.; ZHANG, J.; YE, J.; PAN, G.; WANG, S.; XIAO, P.; HANZO, L. Low earth orbit satellite security and reliability: Issues, solutions, and the road ahead. **IEEE Communications Surveys & Tutorials**, v. 25, n. 3, p. 1604–1652, 2023.
- ZHAO, B.; REN, G.; DONG, X. Joint noma clustering and power allocation in iot-oriented satellite terrestrial relay networks. **IEEE Transactions on Vehicular Technology**, v. 71, n. 10, p. 11078–11088, 2022.
- ZHAO, B.; REN, G.; DONG, X.; ZHANG, H. Distributed q-learning based joint relay selection and access control scheme for iot-oriented satellite terrestrial relay networks. **IEEE Communications Letters**, v. 25, n. 6, p. 1901–1905, 2021.
- ZHAO, B.; WANG, M.; XING, Z.; REN, G.; SU, J. Integrated sensing and communication aided dynamic resource allocation for random access in satellite terrestrial relay networks. **IEEE Communications Letters**, v. 27, n. 2, p. 661–665, 2023.
- ZHOU, D.; SHENG, M.; WANG, Y.; LI, J.; HAN, Z. Machine learning-based resource allocation in satellite networks supporting internet of remote things. **IEEE Transactions on Wireless Communications**, v. 20, n. 10, p. 6606–6621, 2021.

**ANEXO A – ARTIGO PUBLICADO**



Full length article

## Performance analysis of *Q*-learning-based NOMA in Satellite–Terrestrial Relay Networks

Leonardo Pacheco de Aguiar<sup>a</sup>, Marcos Eduardo Pivaro Monteiro<sup>b</sup>,\*, Jamil Farhat<sup>b</sup>, Guilherme de Santi Peron<sup>a</sup>, Glauber Brante<sup>b</sup>

<sup>a</sup> Graduate Program in Energy Systems (PPGSE-CT), Federal University of Technology - Paraná, Curitiba, 80230901, PR, Brazil

<sup>b</sup> Graduate Program in Electrical and Computer Engineering (CPGEI-CT), Federal University of Technology - Paraná, Curitiba, 80230901, PR, Brazil



### ARTICLE INFO

**Keywords:**  
Internet of Things  
*Q*-learning  
Non-orthogonal multiple access  
Artificial intelligence

### ABSTRACT

In this paper, we analyze the performance of *Q*-learning-based Non-Orthogonal Multiple Access (NOMA) in Satellite–Terrestrial Relay Networks (STRNs), addressing key challenges in massive Internet of Things (IoT) communications. Specifically, we focus on energy efficiency and normalized throughput metrics in uplink scenarios. By integrating a distributed *Q*-learning algorithm with NOMA, IoT devices can autonomously optimize transmission parameters – such as time slots, channels, and power levels – enhancing overall network performance. The proposed scheme outperforms fixed-power strategies by achieving higher normalized throughput and energy efficiency under varying network densities, offering up to 73% improvement in energy efficiency. Simulation results validate the protocol's effectiveness, demonstrating its potential for large-scale IoT deployments in STRNs through efficient power allocation and reduced collision rates.

### 1. Introduction

The Internet of Things (IoT) is a transformative technology that enables seamless communication among a wide range of devices. Its rapid adoption in daily life has been fueled by the proliferation of smart services and products [1]. IoT use cases are broadly categorized into two main types: (i) critical IoT, which involves a limited number of high-data-rate devices requiring ultra-reliable low-latency communication (URLLC), and (ii) massive IoT, characterized by a vast number of low-power, low-cost devices designed to transmit minimal amounts of data.

A significant challenge in massive IoT communications is the limited capacity of devices for long-distance transmission [2]. Low-Earth-Orbit (LEO) satellites offer a promising solution, providing lower latency compared to satellites in higher orbits. Due to their proximity to Earth, LEO satellites enhance connectivity in remote areas by minimizing signal loss, enabling transmitters to operate at reduced power levels, which improves both energy efficiency and network performance [3]. However, the uplink capabilities of IoT devices are often constrained by limited transmission power, which can impede direct communication with LEO satellites. Terrestrial relay stations are frequently used as intermediaries to address this limitation, forming the Satellite–Terrestrial Relay Network (STRN) [4]. An advanced version of this framework, known as the Hybrid Satellite–Terrestrial Relay Network

(HSTRN), integrates satellite and terrestrial relay systems to optimize data transmission by mitigating signal degradation and addressing coverage gaps [5].

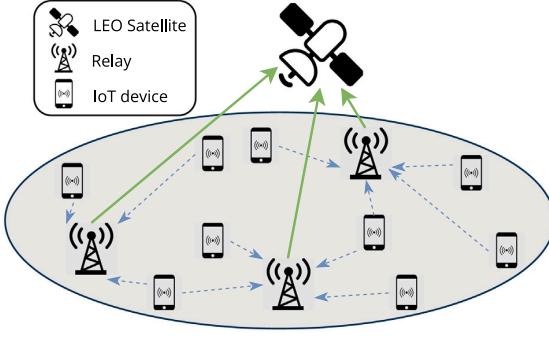
Several studies have analyzed STRNs and HSTRNs to enhance their performance [6–8]. In [6], an STRN scheme is proposed, dividing communication into detection and random access phases, with techniques to minimize interference and dynamically optimize transmission efficiency. The impact of obstacles and shadowing in HSTRNs is examined in [7], where a scheduling system based on Signal-to-Noise Ratio (SNR) is introduced to improve bit error rates. Finally, [8] presents a hybrid HSTRN model employing relays to mitigate signal degradation, enhance coverage, and reduce latency, thereby improving overall network efficiency.

An additional concern in massive IoT scenarios is the medium access strategy and the scarcity of resources needed to ensure massive connectivity. Grant-Free (GF) schemes integrated with Non-Orthogonal Multiple Access (NOMA) address these issues by enabling devices to transmit without handshaking, reducing congestion, and improving random access efficiency [9]. NOMA further supports massive IoT by allowing multiple users to share resources effectively [10], employing different power levels to optimize spectral efficiency and energy performance.

Efficient resource allocation can be effectively achieved through the application of machine learning techniques. In [11], the integration of

\* Corresponding author.

E-mail address: [marcose@utfpr.edu.br](mailto:marcose@utfpr.edu.br) (M.E. Pivaro Monteiro).



**Fig. 1.** The system model consists of  $D$  IoT devices distributed within a circular area of radius  $R$ . These devices are supported by  $R$  relay nodes, which establish connectivity to a LEO satellite.

NOMA with  $Q$ -Learning in STRNs is explored to dynamically optimize access probabilities and relay strategies, thereby improving throughput and reducing latency in massive IoT deployments. In [12], the TROVE vehicular network model uses reinforcement learning to dynamically assess communication security and efficiency in VANETs. Given the constant motion of vehicles and the need for trusted exchanges, TROVE evaluates interactions using parameters like geographical position, network conditions, traffic density, and weather, ensuring adaptive trust management. In [13], the influence of both supervised and unsupervised machine learning algorithms on the optimization of IoT networks with satellite communication is studied. The proposed system is capable of distributing network resources equitably among remote devices in real-time, ensuring efficient and adaptive allocation based on the communication needs of each device. In [14], a decentralized NOMA clustering strategy is proposed, where IoT devices are grouped using  $Q$ -Learning, and optimal power allocation is determined by an algorithm based on the Karush–Kuhn–Tucker (KKT) conditions. To reduce complexity, computations are performed offline by relays, with each cluster using distinct channels to minimize interference. In [15], the ICRA network employs an intelligent decentralized clustering approach to improve UAV communication reliability and efficiency. With high mobility and limited resources, ICRA assigns cluster leaders to manage communications, mitigating congestion, energy consumption, and failures.

Building on the above literature, this work employs the  $Q$ -Learning algorithm for optimizing random access in an STRN of IoT devices. The optimization follows a decentralized strategy, where each IoT device maintains its own  $Q$ -Table, updated by a single bit from the relay indicating transmission success or failure. Additionally, successive interference cancellation (SIC) combined with NOMA is utilized, enabling multiple users to share the same channel by allocating different transmission power levels. Unlike [11], which applies fixed power allocation, and [12,15], which use machine learning for trust management and clustering, respectively, this work enhances the  $Q$ -Learning approach by incorporating dynamic power level allocation. This allows for adaptive transmission strategies that improve both network efficiency and scalability in IoT-based STRNs. Moreover, our methodology evaluates not only system throughput but also energy efficiency as a key performance metric. The results show that our algorithm improves throughput and enables the relay to determine optimal power levels, optimizing power consumption and significantly improving energy efficiency.

## 2. System model

We consider a scenario in which  $D$  IoT devices, distributed within a circular area of radius  $R$ , communicate with  $R$  terrestrial relay

nodes, as illustrated in Fig. 1. These relay nodes play a critical role in forwarding transmissions to a LEO satellite. This assumption reflects practical situations where direct communication between IoT devices and the satellite is infeasible due to constraints such as limited power and computational resources,<sup>1</sup> [9,14].

Medium access is provided through a grant-free slotted Aloha scheme, where  $F$  frames are divided into  $T$  time slots. Each  $d$ th IoT device transmits in a time slot  $t \in [1, \dots, T]$ , selecting a channel  $c \in [1, \dots, C]$ . Additionally, a SIC-NOMA strategy is employed, utilizing  $K$  predefined transmission power levels, enabling each IoT device to choose one of these  $K$  power levels for its transmission in each time slot.

Consequently, the signal received at the  $r$ th relay from the  $d$ th IoT device is expressed as<sup>2</sup>

$$y_{d,r} = \sqrt{P_k k_{d,r} h_{d,r}} x_d + n_r, \quad (1)$$

where  $P_k$  is the transmit power selected by the  $d$ th IoT device from the  $K$  available power levels,  $x_d$  is the transmitted signal, and  $h_{d,r}$  is the channel coefficient between the  $d$ th IoT device and the  $r$ th terrestrial relay, with its magnitude following a Nakagami- $m$  distribution. Additionally,  $n_r$  represents the additive white Gaussian noise (AWGN) with power  $N = N_0 B N_f$ , where  $N_0$  is the unilateral noise power spectral density,  $B$  is the bandwidth, and  $N_f$  is the noise figure. Finally, the path-loss parameter  $k_{d,r}$  follows the model described in [16], with

$$k_{d,r} = -128.1 - 37.6 \log_{10}(d_{d,r}), \quad (2)$$

where  $d_{d,r}$  is the distance between the  $d$ th IoT device and the  $r$ th terrestrial relay.

Since a NOMA-assisted strategy is employed, the relay can decode transmissions from multiple devices sharing the same time slot and channel using a SIC decoding approach. When multiple messages are received simultaneously, the decoding process begins with the signal that has the highest SNR, while others are initially treated as interference. Once the first signal is decoded, the signal with the next highest SNR is processed, treating the remaining signals as noise. This iterative process continues until all messages are successfully decoded or the noise level becomes too high to enable further decoding.

Accordingly, the signal-to-interference-plus-noise ratio (SINR) for the  $d$ th device at the  $r$ th relay is given by

$$\text{SINR}_{(d,r)} = \frac{P_k |h_{d,r}|^2}{\sum_{l=d+1}^k P_l |h_{d,r}|^2 + N}. \quad (3)$$

Therefore, for successful decoding of the transmitted signal at the relay node, the received SINR must exceed a predefined threshold, leading to

$$\mathcal{O} = \Pr \{ \log_2(1 + \text{SINR}_{(d,r)}) \geq \beta \}, \quad (4)$$

where  $\beta$  denotes the target rate (in bps/Hz). A transmission outage event occurs when the SINR falls below the threshold, preventing the relay from decoding the transmitted message.<sup>3</sup>

### 2.1. System metrics

To evaluate the performance of the proposed framework, we define two metrics: normalized throughput and energy efficiency.

<sup>1</sup> Consistently with [14] we assume that the relay nodes operate under more relaxed computational and power constraints compared to the IoT devices.

<sup>2</sup> We omit the indices  $t$  and  $c$  for simplicity, as time slot-channel pairs are mutually orthogonal.

<sup>3</sup> We consider a scenario in which the relays are dedicated devices, resulting in a negligible outage probability over the relay-satellite link compared to the device-relay link.

### 2.1.1. Normalized throughput

Following [11], we define normalized throughput as a metric that quantifies the efficiency of frame utilization by IoT devices. This metric is expressed as

$$\tau = \frac{\beta}{C} \cdot \frac{\delta_s}{T} \cdot \frac{\mu_{\text{dist}}}{\mu_{\text{total}}} \quad [\text{bps/Hz}], \quad (5)$$

where  $\delta_s$  is the average number of IoT devices that successfully transmitted a message to at least one of the available relays during each frame. In addition,  $\mu_{\text{dist}}$  represents the average number of distinct messages successfully received by the satellite from IoT devices in each frame, while  $\mu_{\text{total}}$  denotes the total number of messages received by the satellite in each frame.

### 2.1.2. Energy efficiency

We also evaluate the framework's performance using an energy efficiency metric, defined as the ratio of the average number of distinct messages successfully received to the total power consumption associated with all transmissions over the frame. The energy efficiency metric is expressed as

$$\eta = \frac{\mu_{\text{dist}}}{P_{\text{total}}} \quad [\text{msg/W}], \quad (6)$$

where

$$P_{\text{total}} = \frac{1}{\zeta} \sum_{k=1}^K P_k \delta_k + D (P_{\text{TX}} + P_{\text{RX}}). \quad (7)$$

Here, the term  $\sum_{k=1}^K P_k \delta_k$  represents the average total transmission power used by all users, with  $P_k$  being the power level associated with level  $k$  in the SIC-NOMA strategy and  $\delta_k$  denoting the average number of users selecting this power level over the frame, with  $\sum_{k=1}^K \delta_k = D$ . Additionally, the parameters  $P_{\text{TX}}$  and  $P_{\text{RX}}$  account for the power consumed by the transmission and reception circuitry of the IoT devices,<sup>4</sup> respectively, while  $\zeta$  represents the efficiency of the power amplifier.

## 3. Proposed protocol

In the proposed protocol, referred to as QL-MP-NOMA, we leverage the benefits of a distributed *Q*-learning approach to enable each IoT device to select the optimal parameter allocation for accessing the wireless medium. The *Q*-learning method is a machine-learning algorithm based on the concepts of agent, state, and action. The algorithm utilizes a *Q*-table with dimensions  $S \times A$ , where  $S$  represents the set of possible states the agent can occupy, and  $A$  represents the set of possible actions the agent can take. In other words, *Q*-learning operates with a finite number of states and actions, which are stored in its *Q*-table. Each IoT device stores and manages its own *Q*-table. Then, at each time slot, an agent  $i$  belonging to a state  $S_i$  performs an action  $A_i$  in an attempt to maximize its reward. The updates in *Q*-table are given by the following expression

$$Q(S_i, A_i) \leftarrow (1 - \alpha) Q(S_i, A_i) + \alpha \left[ \epsilon + \gamma \max_a Q(S_{i+1}, a) \right], \quad (8)$$

where  $\gamma$  is the discount factor and  $\alpha$  is the learning rate. The parameter  $\gamma$  regulates the trade-off between the significance of future and immediate rewards. Specifically, when  $\gamma$  approaches 1, the system emphasizes long-term rewards, fostering a strategy that prioritizes future gains. In contrast, lower values of  $\gamma$  lead the system to assign greater importance to immediate rewards, giving priority to short-term optimization. On the other hand, the parameter  $\alpha$  influences the learning rate of the system. When close to 1, it can speed up learning but may also introduce instability by making the system overly reactive to recent changes. Conversely, lower values of  $\alpha$  result in a more gradual learning process, but

<sup>4</sup> The power consumed by the reception circuit corresponds to the energy required for receiving the feedback bit. Furthermore, as all IoT devices transmit within the frame, the power consumed by the transmission and reception circuitry is influenced by the number of IoT devices in the network ( $D$ ).

### Algorithm 1: *Q*-Learning Based Allocation Method.

---

```

Input: Q-Table initialized with 0's in all positions
1 forall  $f \in [1, F]$  do
2   forall  $t \in [1, T]$  do
3     IoT devices choose the timeslot  $t$ , channel  $c$  and power
      level  $P_k$  corresponding to the highest Q-value to
      transmit;
4     Relays employ SIC to decode possible superimposed
      messages transmitted at the same channel and time
      slot;
5     Relays broadcast a single feedback bit per timeslot,
      following  $\epsilon$ ;
6   end
7   forall  $i \in [1, D]$  do
8     IoT device  $i$  updates its Q-Table using (8);
9   end
10 end
11 Relays forward the decoded messages to the satellite;

```

---

the system becomes less sensitive to sudden and occasional variations that might occur in the environment. The continuous updating of the *Q*-table enables the agent to learn and improve its actions over time by adjusting its decisions based on received rewards and estimates of future rewards [17]. The reward function,  $\epsilon$ , equals 1 for a correctly decoded message and -1 otherwise.

### 3.1. Proposed *Q*-learning based allocation method

The operation of the proposed *Q*-learning-based scheme involves each IoT device maintaining its own *Q*-table. At the beginning of each frame, each IoT device selects the action corresponding to the highest value in its *Q*-table. This selection determines the transmission parameters, including the channel, time slot, and transmission power level. Therefore, the *Q*-table is represented as a three-dimensional matrix with dimensions  $C \times T \times K$ .

Once the transmission parameters are selected, the device transmits its message to all available relays within the coverage area. Each relay attempts to decode the signal using SIC. After all transmissions in the frame are completed, a feedback bit is broadcast to all devices indicating the success or failure of its transmission. Based on this feedback, the devices update their *Q*-tables with the new information. In the subsequent frame, the updated *Q*-table increases the likelihood of optimizing transmissions by selecting the most appropriate time and parameters for sending messages. The proposed protocol is detailed in Algorithm 1.

### 3.2. Practical aspects

In this subsection, we focus on key considerations for implementing the proposed approach in real-world scenarios. Specifically, we address aspects related to memory, scalability, and computational complexity to ensure practical feasibility and performance.

- **Memory:** The proposed protocol adopts a distributed approach, where each IoT device computes its own *Q*-Table. For this, each device must have adequate storage capacity to maintain a matrix of dimensions  $C \times T \times K$ , representing the channel, time slot, and power choices for communication.
- **Computational Complexity:** The *Q*-learning approach uses a first-order equation to update the values in the *Q*-Table. As a result, the computational load for each device remains minimal, which is particularly suitable for meeting the strict requirements of large-scale IoT networks.

- Scalability:** The system adopts a distributed approach, where each IoT device is responsible for optimizing its own transmission parameters. Additionally, since the relays broadcast single-bit feedback to the IoT devices at the end of each time slot, independent of the system's scale, this approach optimizes communication across the network and ensures scalability. As the number of devices in the network increases, the distributed nature of the system minimizes the need for centralized coordination, enabling the network to efficiently manage higher device densities. However, when the number of devices exceeds a certain threshold, additional resources, such as more channels or time slots, can be introduced to allow the system to accommodate more devices without significant performance degradation.
- Channel State Information (CSI):** A challenge for SIC-NOMA is signal degradation caused by inaccurate CSI estimation, which can introduce additional interference to the SIC process, as discussed in [18,19]. To mitigate this issue, one alternative is to introduce an additional margin in the power level definition. This margin can be appropriately allocated based on the average expected error in CSI estimation to ensure robust SIC and guarantee successful decoding.

#### 4. Numerical results

In this section, we evaluate the performance of the QL-MP-NOMA scheme using the normalized throughput ( $\tau$ ) and energy efficiency ( $\eta$ ) metrics. Unless stated otherwise, we assume a single transmission channel, a satellite altitude of 780 km, and a circular area of radius  $R = 5$  km with  $R = 4$  relays. Based on [11], we assume  $N_f = 6$  dB,  $B = 100$  kHz,  $\beta = 3$  bps/Hz,  $\alpha = 0.1$ , and  $\gamma = 0.5$ . As for the Nakagami- $m$  fading, we assume  $m = 2$ , which represents environments with moderate fading and a good line-of-sight, being a commonly used value [11,20]. We also assume  $P_{\text{TX}} = 0.025$  W and  $P_{\text{RX}} = 0.099$  W [21],  $N_0 = -174$  dBm/Hz [22], and  $\zeta = 0.667$  [23]. The results are averaged over 100 simulation runs, each consisting of 500 frames with 101 time slots per frame [24]. For the proposed QL-MP-NOMA scheme, we consider  $K = 4$  power levels starting at 14 dBm with a 9 dB decrement, i.e.,  $P_k \in \{14, 5, -4, -13\}$  dBm.<sup>5</sup>

Figs. 2 and 3 show the normalized throughput and energy efficiency, respectively, as functions of number of devices for the proposed QL-MP-NOMA scheme and the QL scheme with two fixed transmission powers. In Fig. 2, QL-MP-NOMA slightly outperforms the QL scheme with  $P_{\text{fix}} = 14$  dBm for up to  $D = 300$  devices, beyond which the fixed power scheme experiences a significant performance drop. At  $D = 500$ , QL-MP-NOMA achieves a 41.5% improvement over the  $P_{\text{fix}} = 14$  dBm scheme. This is due to QL-MP-NOMA's variable power allocation, which mitigates collisions as the number of devices increases, unlike the QL scheme, which becomes constrained by the number of time slots. The scheme using the lowest fixed power ( $P_{\text{fix}} = -13$  dBm) performs worst due to insufficient power for reliable message decoding. In Fig. 3, QL-MP-NOMA consistently outperforms both fixed power schemes. It achieves a 73.4% improvement in energy efficiency compared to the  $P_{\text{fix}} = 14$  dBm scheme at  $D = 500$ . The  $P_{\text{fix}} = -13$  dBm scheme performs poorly due to the relays' inability to decode messages from insufficient SINR.

Figs. 4 and 5 show  $\tau$  and  $\eta$  as functions of number of devices for the proposed QL-MP-NOMA scheme with  $C \in \{1, 2, 3, 4\}$  channels. Interestingly,  $\tau$  decreases as the number of channels  $C$  increases. While more channels reduce collision probability, they do not necessarily improve throughput, since  $\tau$  is measured per hertz in (5). In contrast,  $\eta$  improves with more channels, as increasing  $C$  provides more orthogonal resources, reducing collisions in the QL-MP-NOMA scheme.

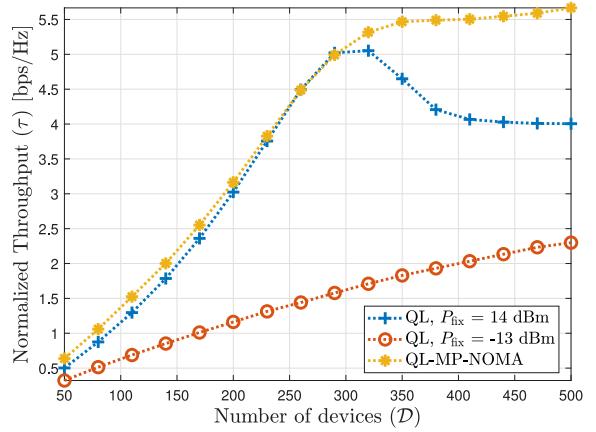


Fig. 2. Normalized throughput ( $\tau$ ) as a function of number of devices ( $D$ ) under different power level strategies.

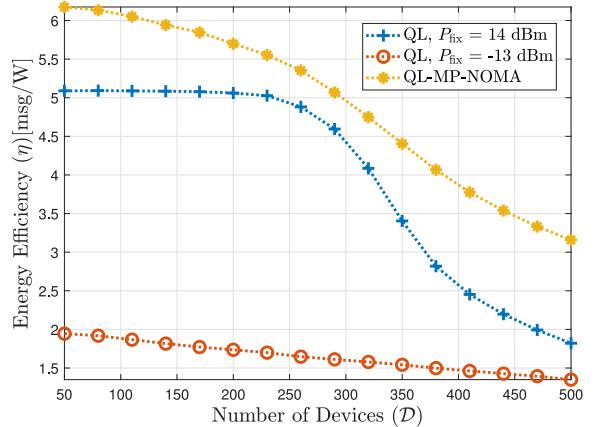


Fig. 3. Energy efficiency ( $\eta$ ) as a function of number of devices ( $D$ ) under different power level strategies.

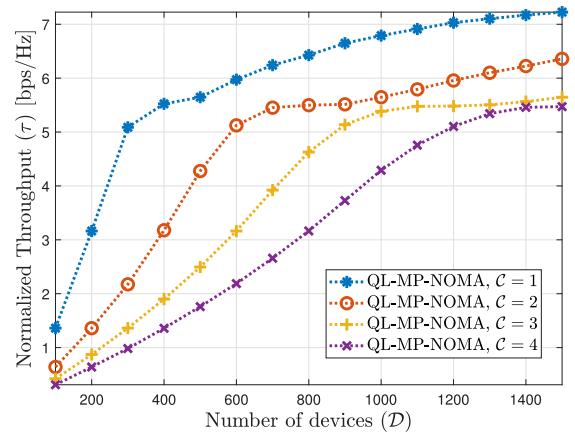


Fig. 4. Normalized throughput ( $\tau$ ) as a function of number of devices ( $D$ ) for  $C \in \{1, 2, 3, 4\}$  channels.

<sup>5</sup> Implementing NOMA systems with a large number of power levels ( $K$ ) is challenging in real-world scenarios [25]. However, our analysis shows that even a small number of power levels can effectively enhance the proposed metrics used to evaluate the performance of the scenario under consideration.

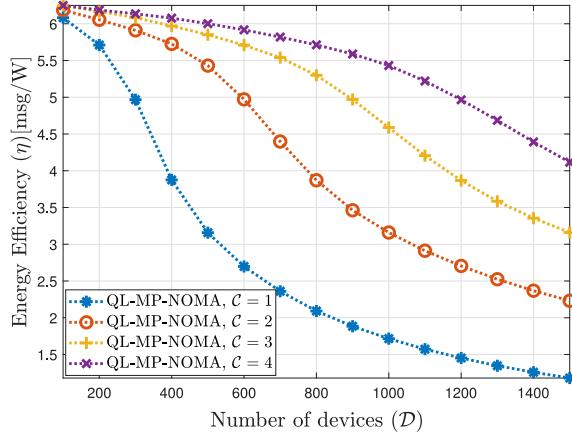


Fig. 5. Energy efficiency ( $\eta$ ) as a function of number of devices ( $D$ ) for  $C \in \{1, 2, 3, 4\}$  channels.

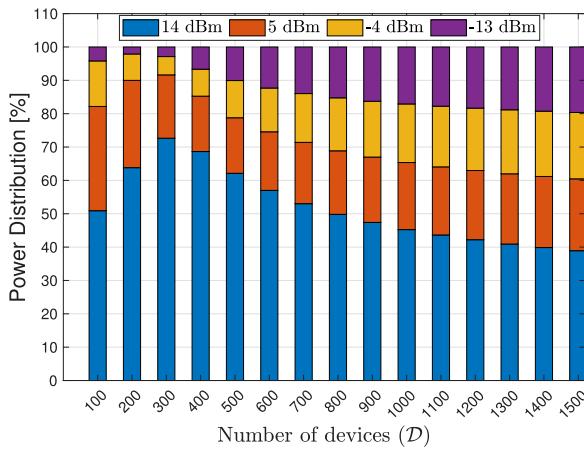


Fig. 6. Power distribution [%] as a function of number of devices ( $D$ ) for  $C = 1$  channel.

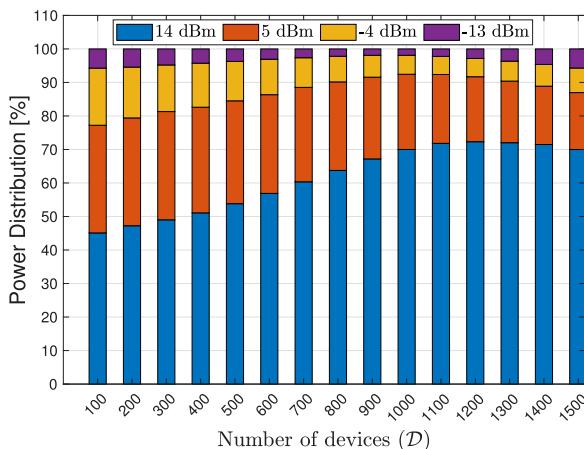


Fig. 7. Power distributions [%] as a function of number of devices ( $D$ ) for  $C = 1$  channels.

Finally, Figs. 6 and 7 analyze the power distribution for  $P_k \in \{14, 5, -4, -13\}$  dBm and  $C \in \{1, 4\}$ . In a single-channel network, saturation occurs at  $D \approx 300$  devices, while in a four-channel network, saturation is delayed and occurs at  $D \approx 1200$ , proportional to the number of available slots. Up to saturation, transmissions at maximum power increase. Once saturation is reached, the QL-MP-NOMA algorithm becomes critical, as it optimizes the use of available transmission powers to maintain and even improve the metrics.

## 5. Conclusions

This paper explores  $Q$ -learning-based NOMA in STRNs to address challenges in massive IoT communications, such as network congestion, energy inefficiency, and reliable decoding. The proposed approach allows IoT devices to dynamically optimize transmission parameters, such as time slots, channels, and power levels, reducing collisions and adapting to network conditions. Simulation results show that the proposed scheme outperforms fixed-power strategies, delivering higher throughput, improved energy efficiency, and longer battery life in dense IoT scenarios.

## CRediT authorship contribution statement

**Leonardo Pacheco de Aguiar:** Writing – original draft, Visualization, Validation, Software, Investigation, Conceptualization. **Marcos Eduardo Pivaro Monteiro:** Writing – review & editing, Supervision, Methodology. **Jamil Farhat:** Writing – review & editing, Methodology, Conceptualization. **Guilherme de Santi Peron:** Writing – review & editing, Supervision, Methodology. **Glauber Brante:** Writing – review & editing.

## Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

## Acknowledgments

This work has been partially supported Agência Nacional de Energia Elétrica and Celesc Distribuição S.A. (PD05697-1323/2023).

## Data availability

No data was used for the research described in the article.

## References

- [1] F. Meneghelli, M. Calore, D. Zucchetto, M. Polese, A. Zanella, IoT: Internet of threats? A survey of practical security vulnerabilities in real IoT devices, *IEEE Internet Things J.* 6 (5) (2019) 8182–8201, <http://dx.doi.org/10.1109/JIOT.2019.2935189>.
- [2] S. Barick, C. Singhal, Multi-UAV assisted IoT NOMA uplink communication system for disaster scenario, *IEEE Access* 10 (2022) 34058–34068, <http://dx.doi.org/10.1109/ACCESS.2022.3159977>.
- [3] P. Yue, J. An, J. Zhang, J. Ye, G. Pan, S. Wang, P. Xiao, L. Hanzo, Low earth orbit satellite security and reliability: Issues, solutions, and the road ahead, *IEEE Commun. Surv. Tutorials* 25 (3) (2023) 1604–1652, <http://dx.doi.org/10.1109/COMST.2023.3296160>.
- [4] K. Guo, K. An, B. Zhang, Y. Huang, D. Guo, G. Zheng, S. Chatzinotas, On the performance of the uplink satellite multiterrestrial relay networks with hardware impairments and interference, *IEEE Syst. J.* 13 (3) (2019) 2297–2308, <http://dx.doi.org/10.1109/JSYST.2019.2901800>.
- [5] K. Guo, C. Dong, K. An, NOMA-based cognitive satellite terrestrial relay network: Secrecy performance under channel estimation errors and hardware impairments, *IEEE Internet Things J.* 9 (18) (2022) 17334–17347, <http://dx.doi.org/10.1109/JIOT.2022.3157673>.

- [6] B. Zhao, M. Wang, Z. Xing, G. Ren, J. Su, Integrated sensing and communication aided dynamic resource allocation for random access in satellite terrestrial relay networks, *IEEE Commun. Lett.* 27 (2) (2023) 661–665, <http://dx.doi.org/10.1109/LCOMM.2022.3227594>.
- [7] Z. Zhao, G. Xu, N. Zhang, Q. Zhang, Symbol error analysis of amplify-and-forward based multiuser hybrid satellite-terrestrial relay network, *IEEE Wirel. Commun. Lett.* 10 (10) (2021) 2279–2283, <http://dx.doi.org/10.1109/LWC.2021.3099302>.
- [8] K. An, T. Liang, Hybrid satellite-terrestrial relay networks with adaptive transmission, *IEEE Trans. Veh. Technol.* 68 (12) (2019) 12448–12452, <http://dx.doi.org/10.1109/TVT.2019.2944883>.
- [9] J. Liu, Z. Shi, S. Zhang, N. Kato, Distributed Q-learning aided uplink grant-free NOMA for massive machine-type communications, *IEEE J. Sel. Areas Commun.* 39 (7) (2021) 2029–2041, <http://dx.doi.org/10.1109/JSAC.2021.3078496>.
- [10] A. Emir, F. Kara, H. Kaya, H. Yanikomeroglu, DeepMuD: Multi-user detection for uplink grant-free NOMA IoT networks via deep learning, *IEEE Wirel. Commun. Lett.* 10 (5) (2021) 1133–1137, <http://dx.doi.org/10.1109/LWC.2021.3060772>.
- [11] D.A. Tubiana, J. Farhat, G. Brante, R.D. Souza, Q-learning NOMA random access for IoT-satellite terrestrial relay networks, *IEEE Wirel. Commun. Lett.* 11 (8) (2022) 1619–1623, <http://dx.doi.org/10.1109/LWC.2022.3169109>.
- [12] J. Guo, X. Li, Z. Liu, J. Ma, C. Yang, J. Zhang, D. Wu, TROVE: A context-awareness trust model for VANETs using reinforcement learning, *IEEE Internet Things J.* 7 (7) (2020) 6647–6662, <http://dx.doi.org/10.1109/JIOT.2020.2975084>.
- [13] D. Zhou, M. Sheng, Y. Wang, J. Li, Z. Han, Machine learning-based resource allocation in satellite networks supporting internet of remote things, *IEEE Trans. Wirel. Commun.* 20 (10) (2021) 6606–6621, <http://dx.doi.org/10.1109/TWC.2021.3075289>.
- [14] B. Zhao, G. Ren, X. Dong, Joint NOMA clustering and power allocation in IoT-oriented satellite terrestrial relay networks, *IEEE Trans. Veh. Technol.* 71 (10) (2022) 11078–11088, <http://dx.doi.org/10.1109/TVT.2022.3186037>.
- [15] J. Guo, H. Gao, Z. Liu, F. Huang, J. Zhang, X. Li, J. Ma, ICRA: An intelligent clustering routing approach for UAV ad hoc networks, *IEEE Trans. Intell. Transp. Syst.* 24 (2) (2023) 2447–2460, <http://dx.doi.org/10.1109/TITS.2022.3145857>.
- [16] Technical Specification Group Radio Access Network; Evolved Universal Terrestrial Radio Access (E-UTRA); Further Advancements for E-UTRA Physical Layer Aspects (Release 9), Tech. Rep. TR 36.814 V9.2.0, 3rd Generation Partnership Project, Sophia Antipolis, France, 2017.
- [17] S. Spanò, G.C. Cardarilli, L. Di Nunzio, R. Fazzolari, D. Giardino, M. Matta, A. Nannarelli, M. Re, An efficient hardware implementation of reinforcement learning: The  $\mathcal{Q}$ -learning algorithm, *IEEE Access* 7 (2019) 186340–186351, <http://dx.doi.org/10.1109/ACCESS.2019.2961174>.
- [18] Y. Gao, B. Xia, Y. Liu, Y. Yao, K. Xiao, G. Lu, Analysis of the dynamic ordered decoding for uplink NOMA systems with imperfect CSI, *IEEE Trans. Veh. Technol.* 67 (7) (2018) 6647–6651, <http://dx.doi.org/10.1109/TVT.2018.2797091>.
- [19] J.F. Gryboski, J.L. Rebelatto, G.L. Moritz, Age of information of SIC-aided massive IoT networks with random access, *IEEE Internet Things J.* 9 (1) (2022) 662–670, <http://dx.doi.org/10.1109/JIOT.2021.3084454>.
- [20] T.-V. Nguyen, T. Huynh-The, V.N. Quoc Bao, Performance analysis and deep learning evaluation of URLLC full-duplex energy harvesting IoT networks over Nakagami-m fading channels, in: 2023 IEEE Statistical Signal Processing Workshop, SSP, 2023, pp. 309–313, <http://dx.doi.org/10.1109/SSP53291.2023.10207990>.
- [21] S. Cui, A. Goldsmith, A. Bahai, Energy-efficiency of MIMO and cooperative MIMO techniques in sensor networks, *IEEE J. Sel. Areas Commun.* 22 (6) (2004) 1089–1098, <http://dx.doi.org/10.1109/JSAC.2004.830916>.
- [22] F. Rosas, R.D. Souza, M.E. Pellenz, C. Oberli, G. Brante, M. Verhelst, S. Pollin, Optimizing the code rate of energy-constrained wireless communications with HARQ, *IEEE Trans. Wirel. Commun.* 15 (1) (2016) 191–205, <http://dx.doi.org/10.1109/TWC.2015.2469289>.
- [23] J.P. Battistella, Nadas, O. Onireti, R.D. Souza, H. Alves, G. Brante, M.A. Imran, Performance analysis of hybrid ARQ for ultra-reliable low latency communications, *IEEE Sensors J.* 19 (9) (2019) 3521–3531, <http://dx.doi.org/10.1109/JSEN.2019.2891221>.
- [24] X. Vilajosana, K. Pister, T. Watteyne, Minimal IPv6 over the TSCH mode of IEEE 802.15.4e (6TiSCH) configuration, 2017, <http://dx.doi.org/10.17487/RFC8180>, Request for Comments 8180 RFC Editor URL <https://www.rfc-editor.org/info/rfc8180>.
- [25] S.M.R. Islam, N. Avazov, O.A. Dobre, K.-s. Kwak, Power-domain non-orthogonal multiple access (NOMA) in 5G systems: Potentials and challenges, *IEEE Commun. Surv. Tutorials* 19 (2) (2017) 721–742, <http://dx.doi.org/10.1109/COMST.2016.2621116>.



**Leonardo Pacheco de Aguiar** was born in Imbituba, SC, Brazil, in 1994. He graduated in Electronic Engineering from the Federal University of Technology – Paraná (UTFPR) in 2020 and is currently pursuing an M.Sc. at the same institution. He has professional experience in Electronic Engineering, having worked for two and a half years on vehicle tracking and telemetry equipment development at Telemachine Telemática. His expertise includes designing and developing electronic devices, focusing on both hardware and firmware solutions.



**Marcos Eduardo Pivaro Monteiro** was born in São Paulo, SP, Brazil, in 1984. He received the B.Sc. and D.Sc. degrees in electrical engineering from the Federal University of Technology – Paraná (UTFPR), Brazil, in 2014 and 2018, respectively. Since August 2018 he has been with the Department of Electronics, UTFPR, where he is currently an Assistant Professor. His research interests are in the areas of coding and information theory, electronics, wireless communications systems, and artificial intelligence.



**Jamil Farhat** received the D.Sc. degree in Electrical Engineering from the Federal University of Technology – Paraná (UTFPR), Curitiba, Brazil, in 2018. He is currently a professor with UTFPR. His research interests include wireless communications, multiple-access strategies, machine-type communications, and physical layer security.



**Guilherme de Santi Peron** was born in Ivaiporã, PR, Brazil, in 1986. He received the B.Sc., M.Sc., and D.Sc. degrees in electrical engineering from the Federal University of Technology-Paraná (UTFPR), Curitiba, Brazil, in 2008, 2012, and 2017, respectively. He has been an Assistant Professor with the Department of Electronics, UTFPR, since 2017. His research interests include cooperative communications, the Internet of Things, energy efficiency, and machine learning.



**Glauber Brante** was born in Arapongas, PR, Brazil. He received the D.Sc. degree in Electrical Engineering from the Federal University of Technology – Paraná (UTFPR), Curitiba, Brazil, in 2013. He is currently an Associate Professor at the same University. From January to September 2012 he was a Visiting Researcher at the Institute of Information and Communication Technologies, Electronics and Applied Mathematics (ICTEAM) at the Catholic University of Louvain, Belgium. His research interests include cooperative communications, HARQ, energy efficiency, and physical layer security. Since 2018 he has been serving as an Associate Editor for IEEE Communications Letters.

**ANEXO B – POLÍTICA DE DIREITOS AUTORAIS DO PERIÓDICO**

5/22/25, 5:10 PM

Copyright | Elsevier policy

[Tell us what you think!](#)

ELSEVIER

[Publish with us](#)

## Elsevier policies

[Home](#) > [About](#) > [Elsevier policies](#) > Policies copyright

# Copyright

[Licensing and copyright option](#)
[Comparing reuse rights](#)
[Publishing Agreements](#)
[CC I](#)

## Authors' licensing and copyright options when publishing research articles with Elsevier

In order for Elsevier to publish and disseminate research articles, we need authors to grant us certain publishing rights, which are determined by the author's choice of publishing model and, in the case of open access articles, the author's choice of end user license.

Irrespective of the model under which an article is published, Elsevier is committed to protecting and defending authors' works and their reputation. We take allegations of infringement, plagiarism, ethical disputes, and fraud very seriously.

Elsevier offers two publishing routes for authors to choose from, which have different implications for authors and others:

1. Pay-to-publish, also known as open access, which usually requires a fee from the author, or their institution or funder, to publish. When publishing open access with Elsevier, the author retains their copyright in the article and grants Elsevier a license to publish it. Authors have a choice of end user license:

- If the author selects a Creative Commons Attribution (CC BY) license, end users are bound by this license. Each author can re-use their article themselves and *also* grant others (additional to Elsevier) a license to re-use their article for any purpose without permission from, or payment to, Elsevier.

5/22/25, 5:10 PM

Copyright | Elsevier policy

- If the author selects a Creative Commons Attribution-NonCommercial-NoDerivatives (CC BY-NC-ND) license or a Creative Commons Attribution-NonCommercial (CC BY-NC) license, end users are bound by the license. Each author retains the right to re-use the article for their own commercial and non-commercial purposes, including creating derivative works, without permission from, or payment to, Elsevier.
2. Pay-to-read, where articles are free to publish, but usually require a subscription or payment to read. When publishing subscription the author typically transfers copyright to the publisher. However, each author retains the right to re-use the article for certain personal and scholarly purposes, including the creation of some derivative works, without permission from, or payment to, Elsevier.

**In all cases, any rights the author grants to Elsevier apply only to the published article. Elsevier does not require, nor ever request, rights to the underlying research itself.** Authors (and institutions or employers) will continue to retain patent, trademark and other intellectual property rights relating to the research, as well as the right to use their research data freely and without restriction.

## Comparing reuse rights

The below tables compare rights for authors and others under the publishing agreements for open access articles (OA) with CC BY, CC BY-NC and CC BY-NC-ND licenses and subscription articles.

### Authors' rights in the article

	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Receive proper attribution and credit for their published work	Yes	Yes	Yes
Re-use their article in their own new works, without permission from Elsevier or payment to	Yes	Yes	Yes

5/22/25, 5:10 PM		Copyright   Elsevier policy	
	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
<p>Elsevier, including by:</p> <ul style="list-style-type: none"> <li>• making copies of the article (or part of the article) to promote companies or products they own, whether or not such promotion is commercial;</li> <li>• including the article in a thesis or dissertation;</li> <li>• extending the article to a book, including the article in a subsequent compilation of their own work, or re-using portions, excerpts, and their own figures, tables and images from the article in their own new works (which in each case may be published with Elsevier or with a third party commercial or non-commercial publisher, at the author's discretion)</li> </ul>			

5/22/25, 5:10 PM	Copyright   Elsevier policy		
	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Use and share their article for scholarly purposes, including: <ul style="list-style-type: none"><li>• for classroom teaching;</li><li>• at conferences;</li><li>• for non-commercial Massive Open Online Courses;</li><li>• create translations of the article and authorize others to do so for non-commercial scholarly collaborations and sharing</li></ul>	Yes	Yes	Yes
Publicly share the <b>preprint</b> anywhere at any time	Yes	Yes	Yes
Publicly share the <b>final published article</b> immediately on <b>non-commercial</b> sites e.g., institutional repositories, ensuring attribution	Yes	Yes	Yes

5/22/25, 5:10 PM	Copyright   Elsevier policy		
	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Publicly share the <b>final published article</b> immediately on <b>commercial scholarly collaboration networks</b> , ensuring attribution, <b>for the purpose only of hosting</b> by those websites	Yes	Yes	Yes
Publicly share the <b>final published article</b> immediately on <b>commercial scholarly collaboration networks</b> , ensuring attribution, <b>for reuse</b> by those websites	Yes	No	No
Publicly share the <b>accepted manuscript</b> on <b>non-commercial sites</b> after an embargo period and attaching a CC BY-NC-ND end user license	Yes	Yes	Yes

5/22/25, 5:10 PM Copyright | Elsevier policy

	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Right to license others to exercise the above rights for commercial purposes	Yes	No	No
Retain copyright of their article	Yes	Yes	Yes

Notes:

- <sup>1</sup>The list is exhaustive in the case of articles published under the subscription model; additional uses/ sharing beyond those listed would require permissions to be requested from Elsevier.
- <sup>2</sup>In the case of articles published under the subscription model: Sharing the Accepted Manuscript for non-commercial Massive Open Online Courses is permitted after the embargo period and provided a CC BY-NC-ND end user license is attached. While the author can create translations of the article for non-commercial scholarly collaborations and sharing, they cannot authorize others to do so.

## Authors' institutions' rights in the article

	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Distribute copies for classroom teaching and internal training purposes	Yes	Yes	Yes

5/22/25, 5:10 PM Copyright | Elsevier policy

	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Include in (online) coursework and courseware programs for use within the institution	Yes	Yes	Yes
Include in non-commercial Massive Open Online Courses	Yes	Yes	Yes
Include in applications for grant funding	Yes	Yes	Yes
Post publicly as part of theses and dissertations, with DOI links to the formal publication	Yes	Yes	Yes

## Elsevier's rights in the article

	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Rights to publish,	Yes	Yes	Yes

5/22/25, 5:10 PM	Copyright   Elsevier policy		
	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
reproduce, display, distribute and otherwise use all or any part of the article, including tables, illustrations or other materials, in print, electronic and all other media (whether now known or later developed)			
To prepare derivative works, in any form, in all languages, throughout the world, for the full term of copyright	Yes	Yes	Yes
The right to license others to exercise the above rights	Yes	Yes	Yes
Manage permissions for third party reuse and adaptation of the work for commercial purposes	No	Yes	Yes

## Others' rights to use the article without permission or payment

	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
Distribute the article for <b>non-commercial</b> purposes	Yes	Yes	Yes
Distribute the article for <b>commercial</b> purposes	Yes	No	No
Include in a collective work (such as an anthology) for <b>non-commercial</b> purposes	Yes	Yes	Yes
Include in a collective work (such as an anthology) for <b>commercial</b> purposes	Yes	No	No
Create and distribute revised versions, adaptations or derivative works of or from an article (such as a translation) for	Yes	Yes	No

5/22/25, 5:10 PM Copyright | Elsevier policy

	OA with CC BY	OA with CC BY-NC	OA with CC BY-NC-ND
non-commercial purposes			
Create and distribute revised versions, adaptations or derivative works of or from an article (such as a translation) for <b>commercial</b> purposes	Yes	No	No
Text or data mine the article for <b>non-commercial</b> purposes	Yes	Yes	Yes <sup>1</sup>
Text or data mine the article for <b>commercial</b> purposes	Yes	No	No

Notes:

- Users accessing content as part of a subscription agreement may have additional rights under that agreement. Users should contact their library or subscription management group for more information.
- Further permission may be required from the rights owner for any content within an article that is identified as belonging to a third party.
  - <sup>1</sup>In line with the terms of the end user license, adaptations cannot be shared with others.
  - <sup>2</sup>Where legal access is obtained by a user, that user is able to text or data mine subscription articles for non-commercial purposes without sharing any adaptation of

5/22/25, 5:10 PM

Copyright | Elsevier policy

the original content with others.

## Publishing Agreements at Elsevier

Authors publishing with Elsevier sign a Publishing Agreement. This has several important functions, including to confirm the author has complied with publishing ethics policies and that the published article will be the final version of record. When publishing open access, the publishing agreement will set out the terms of the license the author grants to Elsevier to publish their article. In the case of publishing subscription, the agreement will transfer copyright to Elsevier and set out reuse rights to the work. Note: In some circumstances, authors may instead grant Elsevier (or the learned society on whose behalf we publish) an exclusive license to publish and disseminate their work. Please see links to sample Publishing Agreements below.

## Additional information on how Elsevier manages commercial licenses for open access articles published under CC BY-NC-ND or CC BY-NC licenses

Our experience, based on requests from authors globally across decades, is that the rights that authors themselves have, when publishing open access under a non-commercial Creative Commons license (outlined above), cover the vast majority of the situations in which authors wish to use their work. Authors who are unclear whether their intended use is covered by these rights, should submit their enquiry [here ↗](#) to obtain further guidance.

Elsevier sometimes receives direct requests from third parties, such as pharmaceutical companies, to re-use and adapt the article. Elsevier maintains relationships with service providers (such as Rightslink and other reproduction rights organizations) to manage these requests. Elsevier incurs costs in undertaking these activities, and may charge third parties a fee when granting permissions for re-use or adaptation of the article.

Authors publishing under the CC BY-NC-ND or CC BY-NC licenses agree not to license any third party to reuse their articles or any part of their articles for commercial purposes. Elsevier has the exclusive right to license third parties to do this. This enables Elsevier to ensure compliance with applicable laws and regulations and control over appropriate commercial use by third parties.

## Authors who are government employees

5/22/25, 5:10 PM

Copyright | Elsevier policy

For US government employees, works created within the scope of their employment are considered to be public domain and Elsevier's publishing agreements do not require a transfer or license of rights for such works.

In the UK and certain commonwealth countries, a work created by a government employee is copyrightable, but the government may own the copyright (Crown copyright). Click [here](#) for information about UK government employees publishing open access.

## Authors publishing in society-owned journals

Please note that the above terms may differ for society-owned journals. Please refer to the journal homepage and Guide for Authors, or contact the journal for further information.

### Find out more

- Download a sample publishing agreement for articles financed by journal subscriptions in [English](#), [French](#) and [Spanish](#)
- Download a sample publishing agreement for articles published open access with a commercial user license (CC BY) in [English](#), [French](#), and [Spanish](#)
- Download a sample publishing agreement for articles published open access with a non-commercial user license (CC BY-NC-ND) in [English](#), [French](#), and [Spanish](#)
- Download a sample publishing agreement for articles published open access with a non-commercial user license (CC BY-NC) in [English](#), [French](#), and [Spanish](#)
- For authors who wish to self-archive see our [sharing guidelines](#)
- See our [author pages](#) for further details about how to promote your article
- See our [hosting](#) page for additional information on hosting research published by Elsevier
- For use of Elsevier material not defined here please see our [permissions page](#) or visit the [Permissions Support Center](#)
- If an author has become aware of a possible plagiarism, fraud or infringement we recommend contacting their Elsevier publishing contact who can then liaise with our in-house legal department
- If you are publishing in a society or third party owned journal, they may have different publishing agreements. Please see the journal's Guide for Authors for journal specific copyright information

### Frequently asked questions

5/22/25, 5:10 PM

Copyright | Elsevier policy

How have you arrived at this set of reuse and sharing rights? 

---

Which OA license is best? 

---

Why does Elsevier have more rights for articles published under the subscription model? 

---

## Useful links

[Submit your paper](#)

[Shop Books & Journals !\[\]\(ce7c5d6a792a8783ba1f4b0eeb0acbd0\_img.jpg\)](#)

[Open access](#)

[View all products](#)

[Elsevier Connect](#)

## About

[About Elsevier](#)

[Careers](#)

[Global Press Office](#)

[Advertising, reprints & supplements !\[\]\(c8c4741e5bbb8d2e224fad5bba5aa52e\_img.jpg\)](#)

[Modern slavery act statement !\[\]\(cae60ec0d680756f33be42947c09c0be\_img.jpg\)](#)

## Support

[Customer support](#)

[Resource center !\[\]\(3b8bb2f625483be2543bc7366e3315ba\_img.jpg\)](#)

Global | English

---



Copyright © 2025 Elsevier, its licensors, and contributors. All rights are reserved, including those for text and data mining, AI training, and similar technologies.

[Terms & Conditions](#)   [Privacy policy](#)   [Accessibility](#)   [Cookie settings](#)