



DANH MỤC CÁC CÔNG TRÌNH ĐÃ CÔNG BỐ

NCS: NGUYỄN THỊ YẾN LINH



Tháng 06/2025

DANH MỤC CÔNG TRÌNH ĐÃ CÔNG BỐ CỦA NGHIÊN CỨU SINH

Tạp chí Quốc tế

- [1]. **N. T. Y. Linh**, P. N. Son, and V. N. Q. Bao, "*Intelligent reflecting surface-assisted beamforming-NOMA networks for short-packet communications: Performance analysis and deep learning approach*," IET Communications, vol. 17, no. 16, pp. 1940-1954, Aug.2023, doi: 10.1049/cmu2.12667. **(SCIE-Q2)**
- [2]. **N. T. Y. Linh**, T. Ngo Hoang, P. N. Son, and V. N. Q. Bao, "*Dual-hop Relaying Networks for Short-Packet URLLCs: Performance analysis and Optimization*," Journal of Communications and Networks, vol. 24, no. 4, pp. 408-418, Aug. 2022, doi: 10.23919/JCN.2022.000020. **(SCIE-Q1)**

Tạp chí trong nước

- [3]. **N. T. Y. Linh**, V. N. Q. Bảo, and P. N. Son, "*Dự đoán công suất tối ưu nguồn phát của hệ thống truyền gói tin ngắn qua mặt phản xạ thông minh bằng kỹ thuật học sâu*," Journal of Science and Technology on Information and Communications, vol. 1, no. 1A, pp. 11-18, Apr. 2023.
- [4]. **N. T. Y. Linh**, V. N. Q. Bao, Pham Ngoc Son, "*Phân Tích Độ Lợi Phân Tập Cho Mạng Chuyển Tiếp Qua Mặt Phản Xạ Thông Minh Và Nút Chuyển Tiếp Trong Truyền Thông Gói Tin Ngắn*," Journal of Science and Technology on Information and Communications (JSTIC), vol. 1, no. 4B, pp. 56-64, Dec.2021.
- [5]. **N. T. Y. Linh**, N. H. Tu, and V. N. Q. Bảo, "*Đánh Giá Hiệu Năng Mạng Chuyển Tiếp Từng Phần Với Đa Anten Thu Trong Truyền Thông Gói Tin Ngắn*," Journal of Science and Technology on Information and Communications, vol. 1, no. 4A, pp. 53-61, Dec.2020.

Kỷ yếu hội nghị quốc tế

- [6]. **N. T. Y. Linh**, P. N. Son, and V. N. Q. Bao, "*Performance Evaluation of Simultaneously Transmitting and Reflecting Intelligent Reflecting Surface - Assisted NOMA Networks for Short-Packet Communications*," in 2023 RIVF International Conference on Computing and Communication Technologies (RIVF), 2023, pp. 194-199, IEEE.

- [7] **N. T. Y. Linh**, P. N. Son, and V. N. Q. Bao, "Power allocation for the STAR-RIS-NOMA Short Packet communication system using Deep Reinforcement Learning," in *2024 International Conference on Advanced Technologies for Communications (ATC)*, 2024, pp. 215-220: IEEE.

IET Communications

Special issue Call for Papers

**Be Seen. Be Cited.
Submit your work to a new
IET special issue**

Connect with researchers and experts in your field and share knowledge.

Be part of the latest research trends, faster.

Read more



The Institution of
Engineering and Technology

ORIGINAL RESEARCH

Intelligent reflecting surface-assisted beamforming-NOMA networks for short-packet communications: Performance analysis and deep learning approach

Nguyen Thi Yen Linh¹ | Pham Ngoc Son¹ | Vo Nguyen Quoc Bao² 

¹Faculty of Electrical and Electronics Engineering,
Ho Chi Minh City University of Technology and
Education, Ho Chi Minh City, Vietnam

²Faculty of Telecommunications, Posts and
Telecommunications Institute of Technology, Ho
Chi Minh City, Vietnam

Correspondence

Vo Nguyen Quoc Bao, Faculty of
Telecommunications, Posts and
Telecommunications Institute of Technology, Ho
Chi Minh City 710372, Vietnam.
Email: baovnq@ptit.edu.vn

Funding information

Ho Chi Minh City University of Technology and
Education, Vietnam, Grant/Award Number:
T2022-02NCS

Abstract

This paper investigates intelligent reconfigurable surface-assisted non-orthogonal multiple access (NOMA) networks for short packet communications where the source with multiple antennas utilizes beamforming technology to serve two end users including a near user and a far user. The analysis system, closed-form expressions of the average block error rates (BLERs), latency and reliability at all users are derived under assuming perfect channel state information over quasi-static Rayleigh fading channels. For evaluating the improvement of the network system, a deep neural network (DNN) framework is designed to predict the performance parameters in two cases: (i) BLERs prediction of the users, (ii) transmit power allocation under the constraints of BLERs at each user which satisfy the extremely high reliability requirements of uRLLCs. The extensive results demonstrate that first, the DNN-based estimation results are more accurate than Monte-Carlo simulation results with low execution time. Second, the allocated power for each user can be accurately predicted at the high layers. Finally, two methods of evaluating the effectiveness of the DNN model, i.e. root mean square error and mean absolute percentage error, reach low error which verify the power of the designed DNN model for future analysis.

1 | INTRODUCTION

1.1 | Background and motivations

The beyond 5th generation wireless networks (5.5G and 6G) will be one of the important components in our future lifestyles, industries, and societies. Because of the prompt demands for the internet of everything (IoE) system and intelligent applications such as industrial automation, tackle internet and vehicle-to-everything (V2X) communications, advanced main services are considered including massive machine-type communications (mMTCs), enhanced mobile broadband (eMBB), and ultra-reliable and low-latency communications (uRLLCs). Especially, uRLLCs will lay the foundation for mission-critical applications with stringent requirements on latency and reliability [1]. For example, factory automation and tactile internet require the delay of 1–10 ms and the ultra-reliability of 99.9999%

[2]. For achieving the requirements of uRLLCs, short-packet communications (SPC) are a dominant solution for next-generation wireless networks designed to support only short packet transmission [3]. In addition, non-orthogonal multiple access (NOMA) is recently proved as one of the pivotal technologies for the future mobile networks in terms of supporting massive connectivity, enhancing spectrum efficiency and further improving reliability and latency [4]. Based on the main strategy of NOMA, multiple users can be served at the same time/frequency/code by power domain allocation method via employing superposition coding (SC) and successive interference cancellation (SIC) [5]. Besides, NOMA's high compatibility with many other potential techniques, e.g. multiple-input multiple-output techniques (MIMO), cooperative networks, millimeter wave communications and intelligent reflecting surface (IRS). Particularly, IRS has regarded as one of breakthrough technologies for revolutionizing wireless

This is an open access article under the terms of the [Creative Commons Attribution-NonCommercial](https://creativecommons.org/licenses/by-nc/4.0/) License, which permits use, distribution and reproduction in any medium, provided the original work is properly cited and is not used for commercial purposes.

© 2023 The Authors. *IET Communications* published by John Wiley & Sons Ltd on behalf of The Institution of Engineering and Technology.

communications which are a lot of outstanding advantages such as (i) smart and reconfigurable propagation environment due to being able to adjust the amplitude and the phase of the incident signal on IRS, (ii) deploying on any surface, e.g. buildings, walls and windows, and (iii) low energy consumption, scalable cost/complexity because the passive elements of IRS do not require dedicated energy resource for transmission or decoding [6, 7]. Inspired by the benefits of NOMA and IRS above, we consider the combination of IRS and NOMA in SPC for aiming to ensure extremely high reliability for uRLLCs. Recently, to guarantee the high quality of service (QoS) and the strict latency of uRLLCs, deep learning (DL) is gained recognition as a feasible solution to solve variety of practical problems, such as performance prediction, congestion control, queue management and resource allocation for IoE systems and modern wireless networks [8]. Especially, DNN which one of potential DL models is considered for minimizing the computational complexity to meet the real-time requirements of future network systems [9].

1.2 | Related works and challenges

Inspired by the great advantages of the above-mentioned techniques, researchers have recently started to study the combination of SPC-NOMA [10–13], and SPC-IRS [14, 15] or SPC-DL in various scenarios [16, 17]. Specifically, Sun et al. first investigated NOMA into SPC for low-latency in wireless networks in ref. [10]. The results of the paper indicate that the effective throughput of NOMA outperforms the effective throughput of OMA with the same blocklength constraint, or incurs lower latency to achieve the same effective throughput target. Then, Yu et al. proved the superior performance of NOMA over OMA in short-packet communications in terms of BLERs for the physical-layer transmission delay reduction in ref. [11]. Next, in ref. [12], Zheng et al. also analyzed the BLERs of downlink NOMA network for SPC over Nakagami-m fading channels in which the users are uniformly distributed in a disc. The paper's results show that the average BLERs of the 2nd and 3rd users significantly decrease despite of the small allocated power. Furthermore, Dung et al. extensively investigated a multiuser downlink MIMO NOMA system over Nakagami-m fading for SPC in [13]. The paper shows MIMO with SPC can significantly improve the performance of NOMA systems via BLERs in ensuring low-latency transmissions. Next, a few works start to consider the association of SPC and IRS as in [15]. Ramin et al. considered the IRS-aided SPC for the uRLLCs system. The results show that the IRS-aided system ensures high reliability and reduces latency as required by many uRLLCs applications in terms of average decoding error probability and achievable rate. By leveraging IRS, in [14] Vu et al. studied the performance of IRS-SNOMA systems under two scenarios, namely perfect and imperfect SIC for serving two users in SPC. The paper's result proved the performance of IRS-SNOMA system achieves better than that of IRS-SOMA through both BLER and throughput. Finally, there are more successes than expected of researchers when incorporating DL

into SPC to meet latency requirements for IoT applications [16, 17]. For example, in ref. [16], Van et al. designed DNN to predict the throughput for SPC in multi-hop wireless-powered IoT networks. The paper shows the DNN's prediction results are accurate and the execution time is shorter than other methods. The authors in ref. [17] proposed a novel multi-output deep-learning framework to simultaneously predict the BLERs and goodputs of the users for wireless-powered cognitive NOMA-IoT networks with SPC. The paper proves the benefits of DL model obtained such as high accuracy, low execution time and reduced computational complexity through lowest indices performance, i.e. RMSE and MAPLE.

1.3 | Main contributions and organizations

Although the above researches on SPC have been taken into consideration in either NOMA, IRS, or DL, most of the existing works have solely focused on Equation (1) analyzing the system performance in terms of BLERs and throughput, Equation (2) simulating to verify the correctness of the results of the system by Monte-Carlo simulation. Generally speaking, there has not been works which completely satisfy the uRLLCs requirements. Specifically, the problem of optimizing the system performance for meeting the conditions of extremely high reliability and low latency in future-generation wireless networks are still unsolved because the objective function for the optimization problem is too complex or not convex. Recently, the SPC-aided DL scenarios have emerged as a powerful tool for network performance evaluation [16, 17] to address the computationally infeasible or overly complex functions of conventional optimization methods. However, for the best of our knowledge, none of the previous works uses DL to solve the system performance optimization problems of SPC under the reliability and latency constraints of uRLLCs.

Motivated by the limitation and the promising joint benefits of IRS, DL, and NOMA networks for SPC, in this paper we investigate the performance of the IRS-aided NOMA networks for SPC in which a beamforming technique is employed to provide the required quality of service (QoS) for all users. Moreover, DL is also proposed to perform tasks, i.e. the system performance and the power allocation prediction under the BLER constraints to satisfy uRLLCs requirements. Thus, our main contributions can be summarized as follows:

- Firstly, we derive the approximated and asymptotic closed-form expressions of the average BLERs for all users, i.e. near user and far user. The result indicates that the average BLER of far user which receives the source's signal by the IRS support decreases rapidly compared to the average BLER of near user in the average and high-SNR regions.
- Secondly, we formulate the approximation of the e2e latency and reliability at all users which considered as new metrics to evaluate objectively the proposed system performance. This reveals the performance at far user is better than that of near user despite the lower power allocation.

TABLE 1 Main notations in the paper.


Notations	Description
$ \cdot $	Absolute value
$\exp(\cdot)$	Exponential function
$\mathbb{V}(\cdot)$ and $\mathbb{E}(\cdot)$	Variance and expectation operator
$\Gamma(\cdot)$	Gamma function
$\Gamma(\cdot, \cdot)$ and $\gamma(\cdot, \cdot)$	Upper and lower incomplete Gamma functions
$Q(\cdot)$	Gaussian Q-function
${}_2F_1(\cdot, \cdot; \cdot; \cdot)$	Gauss hypergeometric function

- Thirdly, we construct a novel DNN framework towards real-time improvement applications in future network systems for predicting the BLERs of the users. The DNN results prove that employing DNN is a promising solution in term of accuracy and extremely short time compared to using the Monte-Carlo methods.
- Finally, we design a general DNN to solve the problem of optimizing system performance due to computational complexity and objective function of non-convex optimization problem by predicting the power allocation to each user under the BLER constraints, which meets the requirements of uRLLCs systems.

Next, In Section 2, we describe the system model as well as analyze the instantaneous signal-to-interference-plus-noise ratio (SINR) for each user. Then, the average BLERs analysis of the proposed system model with both approximate and asymptotic expressions are presented in Section 3. Subsequently, Section 4 discusses the DNN scheme for the considered scenarios. In Section 5, we provide the simulation results and discussions. Eventually, the paper is provided in Section 6. Some of the main notations used throughout the paper are listed as in Table 1.

2 | SYSTEM MODEL

As illustrated in Figure 1, we consider IRS-assisted beamforming-NOMA networks with SPC, where a N -element antenna array-aided base station (BS) exploits NOMA to simultaneously transmit its signals with two single-antenna users (i.e. near user and far user, named as $\mathcal{U}_1$ and $\mathcal{U}_2$, respectively). An IRS with L passive reflecting elements is used to enhance the transmission quality between BS and $\mathcal{U}_2$. We assume that BS can adjust as array, so that its radiation pattern is along the array axis as known as end-fire arrays¹ [18]. We further assume that the direct link between BS and $\mathcal{U}_2$ does not exist due to obstacles from the environments, e.g. trees and buildings. Also, all the channels are assumed to undergo independent and identically distributed (i.i.d.) Rayleigh small-scale fading and to have the same pass-loss exponent.

**FIGURE 1** The model of IRS-assisted beamforming-NOMA networks for SPC.

Employing the principle of NOMA, BS transmits a superposed signal $x_{BS} = \sum_{i=1}^2 \sqrt{\alpha_i P} x_i$ to $\mathcal{U}_i$, where x_i denotes the normalized signal sent to $\mathcal{U}_i$, P is the transmit power at BS, and α_i is the power allocation coefficient of $\mathcal{U}_i$ and $\mathbb{E}\{|x_i|^2\} = 1$. In our proposed system, BS has only one end-fire maximum along the direction of transmission to $\mathcal{U}_1$. For simplicity, we assume that $\alpha_1 > \alpha_2 \geq 0$ and $\alpha_1 + \alpha_2 = 1$.

Thus, the signal received at $\mathcal{U}_1$ and $\mathcal{U}_2$ can be represented, respectively, as

$$y_{\mathcal{U}_1} = \left| \text{AF}(\theta_{\mathcal{U}_1}) \right| h_0 x_{BS} + n_1, \quad (1)$$

and

$$y_{\mathcal{U}_2} = \left| \text{AF}(\theta_{\mathcal{U}_2}) \right| \left(\sum_{l=1}^L h_l r_l g_l \right) x_{BS} + n_2, \quad (2)$$

where $\text{AF}(\theta) = \frac{1}{N} \left\{ \frac{\sin[\frac{N}{2}(\kappa d \cos \theta + \beta)]}{\sin[\frac{1}{2}(\kappa d \cos \theta + \beta)]} \right\}$ is the array factor of the N -element array [18, Eq. (6.27)]; $\theta \in \{\theta_{\mathcal{U}_1}, \theta_{\mathcal{U}_2}\}$ is the radiation angle; $\kappa = \frac{2\pi}{\lambda}$ is the phase factor; β is the phase excitation between the element arrays; $d = \frac{\lambda(N-1)}{2N}$ is the distance of antennas in the antenna arrays; λ is the wavelength; n_i is the additive zero average white Gaussian noise (AWGN) at $\mathcal{U}_i$ with zero mean and variance of N_0 , i.e. $n_i \sim \mathcal{CN}(0, N_0)$ and h_0 is the channel coefficient from BS- $\mathcal{U}_1$ link.

In addition, the l -th reflective element of IRS produces the reflection coefficient as $r_l \triangleq |r_l| e^{j\psi_l}$ ($l = \overline{1, L}$), where ψ_l represents the adjustable phase, $\psi_l \in [0, 2\pi)$, $j^2 = -1$ and $|r_l| = 1$ [19]. The channel coefficient from BS-IRS and IRS- $\mathcal{U}_2$ links are denoted by $h_l = d_1^{-\nu/2} A_l e^{-j\phi_l}$ and $g_l = d_2^{-\nu/2} B_l e^{-j\varphi_l}$, respectively, where d_1 and d_2 are the distances between BS and the center of IRS and the center of IRS and $\mathcal{U}_2$, ν denotes the path loss coefficient, A_l , B_l , ϕ_l , and φ_l are the magnitudes following Rayleigh distribution and the phases of the channel coefficients of h_l and g_l , respectively.

¹ An end-fire array is a linear or planar antenna whose main beam (maximum radiation with radiation angle of 0° or 180°) is along the line or in the plane of the array.

Based on the successive interference cancellations, $\mathcal{U}_1$ with better channel quality can decode directly its signal x_1 , and treat another x_2 , with poor channel condition as noise. Hence, the instantaneous signal-to-interference-plus-noise ratio (SINR) for $\mathcal{U}_1$ can be obtained as

$$\gamma_{\mathcal{U}_1}^{x_1} = \frac{\alpha_1 \Omega_0 G_1 \bar{\gamma}}{G_1 \Omega_0 \alpha_2 \bar{\gamma} + 1}, \quad (3)$$

where $G_1 = |AF(\theta_{S\mathcal{U}_1})|^2$, $\bar{\gamma} = \frac{P}{N_0}$ is the transmit SNR and $\Omega_0 = \mathbb{E}\{|h_0|^2\}$ is the average channel gain at $\mathcal{U}_1$.

At $\mathcal{U}_2$, x_1 is first decoded, where x_2 is treated as interference. Then, the signal is subtracted before decoding the own signal of $\mathcal{U}_2$. The SINR at $\mathcal{U}_2$ for decoding the signal of x_1 and x_2 can be expressed, respectively, as

$$\gamma_{\mathcal{U}_2}^{x_1} = \frac{\alpha_1 P |AF(\theta_{S\mathcal{U}_2})|^2 \left(\sum_{l=1}^L b_l g_l r_l \right)^2}{|AF(\theta_{S\mathcal{U}_2})|^2 \left(\sum_{l=1}^L b_l g_l r_l \right)^2 \alpha_2 P + N_0}, \quad (4)$$

and

$$\gamma_{\mathcal{U}_2}^{x_2} = \frac{\alpha_2 P |AF(\theta_{S\mathcal{U}_2})|^2 \left(\sum_{l=1}^L b_l g_l r_l \right)^2}{N_0}. \quad (5)$$

Assuming that IRS can know perfectly the phases of b_l and g_l .² Thus, IRS can control the phase shifting of each element reflecting within the IRS, i.e. $\psi_l = -(\phi_l + \varphi_l)$ for optimizing the received SINR at $\mathcal{U}_2$. Moreover, we consider the near field of the antenna array, where the distance between BS/ $\mathcal{U}_2$ and the center of IRS is less than $\frac{2D^2}{\lambda}$ with the wavelength of the signal and the maximum size of IRS denoted λ and D , respectively [6].

By setting $G_2 = |AF(\theta_{S\mathcal{U}_2})|^2$ and $\Theta = \sum_{l=1}^L b_l g_l r_l = \sum_{l=1}^L d_1^{-v/2} d_2^{-v/2} A_l B_l$, the maximal SINR at $\mathcal{U}_2$ can be written as

$$\gamma_{\mathcal{U}_2}^{x_1} = \frac{\alpha_1 G_2 \Theta^2 \bar{\gamma}}{G_2 \alpha_2 \Theta^2 \bar{\gamma} + 1}, \quad (6)$$

and

$$\gamma_{\mathcal{U}_2}^{x_2} = \alpha_2 G_2 \Theta^2 \bar{\gamma}. \quad (7)$$

3 | PERFORMANCE ANALYSIS

3.1 | Preliminaries

In this section, some preliminaries are presented for the average BLER calculation at $\mathcal{U}_1$ and $\mathcal{U}_2$, i.e. the cumulative distribution function (CDF) of SINR at $\mathcal{U}_1$ and $\mathcal{U}_2$. As assumed the channels between the users and BS are Rayleigh fading channels. Hence, the channel gain Ω_0 is exponentially distributed random variables (RVs) with the CDF given as [23, Eq. (6.68)]

$$F_{\Omega_0}(x) = 1 - \exp(-\lambda_0 x), \quad (8)$$

where $\lambda_0 = d_0^\nu$ with ν being the path-loss exponent [24] and d_0 being the physical distance of between BS and $\mathcal{U}_1$, respectively. In addition, we can obtain the CDF of $\gamma_{\mathcal{U}_1}^{x_1}$, based on [23, Eq. (4.1)] as

$$F_{\gamma_{\mathcal{U}_1}^{x_1}}(x) = \Pr\left(\frac{\alpha_1 \Omega_0 G_1 \bar{\gamma}}{G_1 \Omega_0 \alpha_2 \bar{\gamma} + 1} < x\right) = \begin{cases} 1, & x \geq \frac{\alpha_1}{\alpha_2}, \\ F_{\Omega_0}\left(\frac{x}{G_1 \bar{\gamma}(\alpha_1 - \alpha_2 x)}\right), & x < \frac{\alpha_1}{\alpha_2}. \end{cases} \quad (9)$$

Combining Equation (9) with Equation (8), the CDF of $\gamma_{\mathcal{U}_1}^{x_1}$ can be written as

$$F_{\gamma_{\mathcal{U}_1}^{x_1}}(x) = \begin{cases} 1, & x \geq \frac{\alpha_1}{\alpha_2}, \\ 1 - \exp\left(-\lambda_0 \frac{x}{G_1 \bar{\gamma}(\alpha_1 - \alpha_2 x)}\right), & x < \frac{\alpha_1}{\alpha_2}. \end{cases} \quad (10)$$

Proposition 1. The CDF of $\gamma_{\mathcal{U}_2}^{x_1}$ and $\gamma_{\mathcal{U}_2}^{x_2}$ at $\mathcal{U}_2$ can be expressed as

$$F_{\gamma_{\mathcal{U}_2}^{x_1}}(x) = \begin{cases} 1, & x \geq \frac{\alpha_1}{\alpha_2}, \\ 1 - \frac{\Gamma\left(a+1, \frac{1}{b} \sqrt{\frac{x}{\alpha_2 G_2 \bar{\gamma}(\alpha_1 - \alpha_2 x)}}\right)}{\Gamma(a+1)}, & x < \frac{\alpha_1}{\alpha_2}. \end{cases} \quad (11)$$

and

$$F_{\gamma_{\mathcal{U}_2}^{x_2}}(x) = 1 - \frac{\Gamma\left(a+1, \frac{1}{b} \sqrt{\frac{x}{\alpha_2 G_2 \bar{\gamma}}}\right)}{\Gamma(a+1)}, \quad (12)$$

where $a = k_1^2/k_2 - 1$, $b = k_2/k_1$, $k_1 = \frac{L\pi}{4} \sqrt{1/d_1^\nu d_2^\nu}$ and $k_2 = L/d_1^\nu d_2^\nu (1 - \frac{\pi^2}{16})$ [25, Lemma 1].

² Effective channel estimation methods are applied to obtain perfect CSI in IRS-assisted wireless networks, such as brute-force methods [20], compressed sensing-based methods [21], and deep learning-based methods [22]

3.2 | Average BLER

In this section, we derive the closed-form expression of the average BLER at $\mathcal{U}_1$ and $\mathcal{U}_2$ for the proposed system under SPC. We assume that BS transmits a packet, in which contains β information bits over blocklength $\mathcal{K}$ to $\mathcal{U}_i$, through quasi-static fading channels³ [26]. The coding rate for each transmission block in the proposed system is given by $\mathcal{R} \triangleq \frac{\beta}{\mathcal{K}}$. According to ref. [27, Equation (59)], when $\mathcal{K}$ achieves sufficient large-value (i.e. $\mathcal{K} \geq 100$ CUs), the maximum achievable rate can be approximated as

$$\mathcal{R} = C(\gamma_{\mathcal{U}_i}^{\mathcal{X}}) - \sqrt{\mathcal{V}(\gamma_{\mathcal{U}_i}^{\mathcal{X}})/\mathcal{K}\mathcal{Q}^{-1}(\varepsilon_{\mathcal{U}_i}^{\mathcal{X}})}, \quad (13)$$

where $\mathcal{X} \in \{x_1, x_2\}$ denotes one type of the intended signal for $\mathcal{U}_i$, $C(\gamma_{\mathcal{U}_i}^{\mathcal{X}}) \triangleq \log_2(1 + \gamma_{\mathcal{U}_i}^{\mathcal{X}})$ is the Shannon channel capacity, $\mathcal{V}(\gamma_{\mathcal{U}_i}^{\mathcal{X}}) \triangleq (1 - 1/(1 + \gamma_{\mathcal{U}_i}^{\mathcal{X}})^2)(\log_2 e)^2$ is the channel dispersion, which measures the stochastic variability of the channel in relation to a destined channel for the same capacity [28], $\varepsilon_{\mathcal{U}_i}^{\mathcal{X}}$ represents the instantaneous BLER for decoding $\mathcal{X}$ at $\mathcal{U}_i$, $\mathcal{Q}^{-1}$ is the inverse function of Q-function with $\mathcal{Q}(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty \exp(-\frac{t^2}{2}) dt$ [29].

From Equation (13), the average BLER for decoding $\mathcal{X}$ at $\mathcal{U}_i$ can be calculated as

$$\bar{\varepsilon}_{\mathcal{U}_i}^{\mathcal{X}} \approx \int_0^\infty \mathcal{Q}\left(\frac{C(\gamma_{\mathcal{U}_i}^{\mathcal{X}}) - \mathcal{R}}{\sqrt{\mathcal{V}(\gamma_{\mathcal{U}_i}^{\mathcal{X}})/\mathcal{K}}}\right) f_{\gamma_{\mathcal{U}_i}^{\mathcal{X}}}(\gamma) d\gamma, \quad (14)$$

where $f_{\gamma_{\mathcal{U}_i}^{\mathcal{X}}}(\cdot)$ is the probability density function of $\gamma_{\mathcal{U}_i}^{\mathcal{X}}$. It is challenging to directly derive the exact closed-form expression of Equation (14) because of the complex form of $\mathcal{Q}(\cdot)$. Fortunately, the linear approximation form of the Q-function, i.e. $\mathcal{Q}\left(\frac{C(\gamma_{\mathcal{U}_i}^{\mathcal{X}}) - \mathcal{R}}{\sqrt{\mathcal{V}(\gamma_{\mathcal{U}_i}^{\mathcal{X}})/\mathcal{K}}}\right) \approx \Xi(\gamma_{\mathcal{U}_i}^{\mathcal{X}})$ is derived [17, Equation (14)] as follows:

$$\Xi(\gamma_{\mathcal{U}_i}^{\mathcal{X}}) = \begin{cases} 1, & \gamma_{\mathcal{U}_i}^{\mathcal{X}} \leq \rho_{iL}, \\ 0.5 - v_i \sqrt{\mathcal{K}}(\gamma_{\mathcal{U}_i}^{\mathcal{X}} - \zeta_i), & \rho_{iL} < \gamma_{\mathcal{U}_i}^{\mathcal{X}} < \rho_{iH}, \\ 0, & \gamma_{\mathcal{U}_i}^{\mathcal{X}} \geq \rho_{iH}, \end{cases} \quad (15)$$

where $v_i = [2\pi(2^{2\mathcal{R}_i} - 1)]^{-1/2}$, $\zeta_i \triangleq 2^{\mathcal{R}_i} - 1$, $\rho_{iH} = \zeta_i + \frac{1}{2v_i\sqrt{\mathcal{K}}}$, and $\rho_{iL} = \zeta_i - \frac{1}{2v_i\sqrt{\mathcal{K}}}$.

Substituting Equation (15) into Equation (14) and using integration method by parts, the average BLER can be rewritten as

$$\bar{\varepsilon}_{\mathcal{U}_i}^{\mathcal{X}} = v_i \sqrt{\mathcal{K}} \int_{\rho_{iL}}^{\rho_{iH}} F_{\gamma_{\mathcal{U}_i}^{\mathcal{X}}}(\gamma) d\gamma. \quad (16)$$

Lemma 1. *Over Rayleigh fading, the average BLER of $\mathcal{U}_1$ can be attained as*

$$\bar{\varepsilon}_{\mathcal{U}_1} = \begin{cases} v_1 \sqrt{\mathcal{K}}(\rho_{1H} - \rho_{1L}), & \frac{\alpha_1}{\alpha_2} \leq \rho_{1L}, \\ v_1 \sqrt{\mathcal{K}}(\rho_{1H} - \rho_{1L} - \mathbf{I}_1), & \rho_{1L} < \frac{\alpha_1}{\alpha_2} < \rho_{1H}, \\ v_1 \sqrt{\mathcal{K}}(\rho_{1H} - \rho_{1L} - \mathbf{I}_2), & \frac{\alpha_1}{\alpha_2} \geq \rho_{1H}, \end{cases} \quad (17)$$

where $\mathbf{I}_1$ and $\mathbf{I}_2$ are given as in Equations (18) and (19), respectively.

$$\mathbf{I}_1 = \frac{\exp\left(\frac{\lambda_0}{\alpha_2 G_1 \bar{\gamma}}\right)}{\alpha_2} \left[(\alpha_1 - \alpha_2 \rho_{1L}) \exp\left(\frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}}\right) - \frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}} \Gamma\left(0, \frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}(\alpha_1 - \alpha_2 \rho_{1L})}\right) \right]. \quad (18)$$

$$\mathbf{I}_2 = \frac{\exp\left(\frac{\lambda_0}{\alpha_2 G_1 \bar{\gamma}}\right)}{\alpha_2} \left\{ (\alpha_1 - \alpha_2 \rho_{1L}) \exp\left(\frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}(\alpha_1 - \alpha_2 \rho_{1L})}\right) - (\alpha_1 - \alpha_2 \rho_{1H}) \exp\left(\frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}(\alpha_1 - \alpha_2 \rho_{1H})}\right) + \frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}} \left[\Gamma\left(0, \frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}(\alpha_1 - \alpha_2 \rho_{1L})}\right) - \Gamma\left(0, \frac{\lambda_0 \alpha_1}{\alpha_2 G_1 \bar{\gamma}(\alpha_1 - \alpha_2 \rho_{1H})}\right) \right] \right\}. \quad (19)$$

Proof. The proof of Lemma 1 is provided in **Appendix A**.

Next, let us consider the average overall BLER at $\mathcal{U}_2$, which is presented by Proposition 2 below. $\square$

Proposition 2. *The average overall BLERs of decoding $\mathcal{X}$ at $\mathcal{U}_2$ can be calculated as*

$$\bar{\varepsilon}_{\mathcal{U}_2} \approx \bar{\varepsilon}_{\mathcal{U}_2}^{x_1} + \bar{\varepsilon}_{\mathcal{U}_2}^{x_2} - \min\left\{\bar{\varepsilon}_{\mathcal{U}_2}^{x_1}, \bar{\varepsilon}_{\mathcal{U}_2}^{x_2}\right\}, \quad (20)$$

where $\bar{\varepsilon}_{\mathcal{U}_2}^{x_1}$ and $\bar{\varepsilon}_{\mathcal{U}_2}^{x_2}$ are the average BLERs for decoding x_1 and x_2 , respectively.

Proof. After performing successfully SIC to decode x_1 and x_2 , the average overall BLERs at $\mathcal{U}_2$ can be calculated as

$$\begin{aligned} \bar{\varepsilon}_{\mathcal{U}_2} &= \mathbb{E}\left\{\varepsilon_{\mathcal{U}_2}^{x_1} + \left(1 - \varepsilon_{\mathcal{U}_2}^{x_1}\right) \varepsilon_{\mathcal{U}_2}^{x_2}\right\} \\ &= \bar{\varepsilon}_{\mathcal{U}_2}^{x_1} + \bar{\varepsilon}_{\mathcal{U}_2}^{x_2} - \mathbb{E}\left\{\varepsilon_{\mathcal{U}_2}^{x_1} \varepsilon_{\mathcal{U}_2}^{x_2}\right\}. \end{aligned} \quad (21)$$

³ Quasi-static fading channels known as the channel in which channel fading coefficients remain the constant value during each transmission block and can change independently in another transmission.

By applying Cauchy inequality in ref. [30, Equation (1.6)] for two real positive values of $\varepsilon_{\mathcal{U}_2}^{x_1}$ and $\varepsilon_{\mathcal{U}_2}^{x_2}$, we have $\varepsilon_{\mathcal{U}_2}^{x_1} \varepsilon_{\mathcal{U}_2}^{x_2} \leq \frac{1}{2}(\varepsilon_{\mathcal{U}_2}^{x_1 2} + \varepsilon_{\mathcal{U}_2}^{x_2 2})$. As a result, we also deduce $\mathbb{E}\{\varepsilon_{\mathcal{U}_2}^{x_1} \varepsilon_{\mathcal{U}_2}^{x_2}\} \leq \frac{1}{2}\mathbb{E}[\varepsilon_{\mathcal{U}_2}^{x_1 2} + \varepsilon_{\mathcal{U}_2}^{x_2 2}]$. It is noted that $\varepsilon_{\mathcal{U}_2}^{x_1}$ and $\varepsilon_{\mathcal{U}_2}^{x_2}$ are small, e.g. 10^{-3} to 10^{-5} [31], we can see clearly that if $\varepsilon_{\mathcal{U}_2}^{x_1} = \varepsilon_{\mathcal{U}_2}^{x_2}$.

$$\begin{aligned} \mathbb{E}\left\{\varepsilon_{\mathcal{U}_2}^{x_1} \varepsilon_{\mathcal{U}_2}^{x_2}\right\} &\leq \mathbb{E}\left[\varepsilon_{\mathcal{U}_2}^{x_1 2}\right] \\ &< \mathbb{E}\left[\varepsilon_{\mathcal{U}_2}^{x_1}\right]. \end{aligned} \quad (22)$$

or

$$\begin{aligned} \mathbb{E}\left\{\varepsilon_{\mathcal{U}_2}^{x_1} \varepsilon_{\mathcal{U}_2}^{x_2}\right\} &\leq \mathbb{E}\left[\varepsilon_{\mathcal{U}_2}^{x_2 2}\right] \\ &< \mathbb{E}\left[\varepsilon_{\mathcal{U}_2}^{x_2}\right]. \end{aligned} \quad (23)$$

Generally, Equations (22) and (23) can written as

$$\mathbb{E}\left\{\varepsilon_{\mathcal{U}_2}^{x_1} \varepsilon_{\mathcal{U}_2}^{x_2}\right\} \approx \min\left\{\varepsilon_{\mathcal{U}_2}^{x_1}, \varepsilon_{\mathcal{U}_2}^{x_2}\right\}. \quad (24)$$

By replacing Equation (24) into Equation (21), we can be obtained as the desired results in Equation (20). $\square$

Lemma 2. From **Proposition 1** and Equation (16), the average BLERs for decoding x_1 and x_2 at $\mathcal{U}_2$ can be obtained as follows:

$$\varepsilon_{\mathcal{U}_2}^{x_1} = \begin{cases} v_2 \sqrt{\mathcal{K}}(\rho_{2H} - \rho_{2L}), & \frac{\alpha_1}{\alpha_2} \leq \rho_{2L}, \\ v_2 \sqrt{\mathcal{K}}\left[(\rho_{2H} - \rho_{2L}) - \frac{2}{\Gamma(a+1)}\mathbf{I}_3\right], & \rho_{2L} < \frac{\alpha_1}{\alpha_2} < \rho_{2H}, \\ v_2 \sqrt{\mathcal{K}}\left[(\rho_{2H} - \rho_{2L}) - \frac{2}{\Gamma(a+1)}\mathbf{I}_4\right], & \frac{\alpha_1}{\alpha_2} \geq \rho_{2H}, \end{cases} \quad (25)$$

and

$$\begin{aligned} \varepsilon_{\mathcal{U}_2}^{x_2} &= v_2 \sqrt{\mathcal{K}} \\ &\times \left\{ (\rho_{2H} - \rho_{2L}) - \frac{2}{\Gamma(a+1)}[\Delta(\sqrt{\rho_{2H}}) - \Delta(\sqrt{\rho_{2L}})] \right\}, \end{aligned} \quad (26)$$

where

$$\begin{aligned} \Delta(x) &= \frac{x^2}{2} \Gamma\left(a+1, \frac{x}{b\sqrt{\alpha_2 G_2 \tilde{\gamma}}}\right) - \frac{x^{a+2}}{\left(b\sqrt{\alpha_2 G_2 \tilde{\gamma}}\right)^a} \\ &\times \frac{e^{\frac{-x}{b\sqrt{\alpha_2 G_2 \tilde{\gamma}}}}}{2} - \frac{(a+2)}{2\left(\frac{1}{b\sqrt{\alpha_2 G_2 \tilde{\gamma}}}\right)^2} \Gamma\left(a+2, \frac{x}{b\sqrt{\alpha_2 G_2 \tilde{\gamma}}}\right). \end{aligned}$$

Proof. The proof of **Lemma 2** is provided in **Appendix B**. $\square$

Remark 1. When $\tilde{\gamma} \rightarrow \infty$, the value of $\mathfrak{F}_L$ and $\mathfrak{F}_H$ in Equations (A16) and (A17) are equal to zero. Therefore, the integral of Equations (A20) and (A21) are all zero. Accordingly, the average BLERs for decoding x_1 at $\mathcal{U}_2$ can be approximated as

$$\varepsilon_{\mathcal{U}_2}^{x_1} = v_2 \sqrt{\mathcal{K}}(\rho_{2H} - \rho_{2L}). \quad (27)$$

Remark 2. We note that the corresponding average latency during transmission of the signal to $\mathcal{U}_i$ which measured in the number of CUs [32, Equation (18)], can be expressed as

$$\tau_i = \frac{\mathcal{K}}{1 - \bar{\varepsilon}_{\mathcal{U}_i}}. \quad (28)$$

Then, reliability of transmitting the signal to $\mathcal{U}_i$ is denoted as the probability that a desirable packet is successfully transferred from the BS to $\mathcal{U}_i$. The reliability δ_i of $\mathcal{U}_i$ can be calculated as

$$\delta_i = (1 - \bar{\varepsilon}_i)100\%. \quad (29)$$

3.3 | Asymptotic BLER

In this subsection, we will find the upper closed-forms of the BLERs at $\mathcal{U}_i$ in the high-SNR regime. The approximation of BLER is used to provide a more objective evaluation of the system performance at high SNR levels. This approximation is considered as an upper bound for BLER values when the average SNR approaches infinity. This means that the system BLER always achieves a value less than or equal to this upper bound, no matter how high the SNR is increased. Furthermore, this is desirable as the lower the block error rate, the better the system performance.

Noted that the integral in Equation (16), the value of $\rho_{iH} - \rho_{iL}$ can be obtained as

$$\rho_{iH} - \rho_{iL} = \zeta_i + \frac{1}{2v_i \sqrt{\mathcal{K}}} - \left(\zeta_i - \frac{1}{2v_i \sqrt{\mathcal{K}}} \right) = \frac{1}{v_i \sqrt{\mathcal{K}}}. \quad (30)$$

By replacing $v_i = [2\pi(2^{2R_i} - 1)]^{-1/2}$ into Equation (30), we have

$$\rho_{iH} - \rho_{iL} = \sqrt{2\pi(2^{2R_i} - 1)/\mathcal{K}}. \quad (31)$$

Under finite block length with $\mathcal{K} \geq 100$, $\rho_{iH} - \rho_{iL}$ is small. Moreover, $F_{\gamma_{\mathcal{U}_i}^x}(\gamma)$ is a real valued function in the interval $[\rho_{iL}, \rho_{iH}]$. As proven to have high precision in ref. [33], Riemann integral approximation method, i.e. $\int_a^b f(\tilde{x})d\tilde{x} \approx (b-a)f\left(\frac{a+b}{2}\right)$ is utilized for Equation (16). The asymptotic BLERs at $\mathcal{U}_i$ is given by

$$\varepsilon_{\mathcal{U}_i}^x \approx F_{\gamma_{\mathcal{U}_i}^x}(\zeta_i). \quad (32)$$

Moreover, based on the equivalent infinitesimal series of $1 - \exp(-\frac{x}{\bar{\gamma}}) \stackrel{\bar{\gamma} \rightarrow \infty}{\sim} \frac{x}{\bar{\gamma}}$ for Equation (10) and then replacing into Equation (32), the asymptotic BLER at $\mathcal{U}_1$ for decoding x_1 can be derived as

$$\tilde{\varepsilon}_{\mathcal{U}_1} \simeq F_{\gamma_{\mathcal{U}_1}}(\zeta_1) \simeq \begin{cases} 1, & \zeta_1 \geq \frac{\alpha_1}{\alpha_2}, \\ \lambda_0 \frac{\zeta_1}{G_1 \bar{\gamma} (\alpha_1 - \alpha_2 \zeta_1)}, & \zeta_1 < \frac{\alpha_1}{\alpha_2}. \end{cases} \quad (33)$$

Next, by applying [28, Equation (8354.2)] for Equations (11) and (12), the asymptotic CDF of $\mathcal{U}_2$ can be rewritten as in Equations (35) and (34), respectively, as

$$F_{\gamma_{\mathcal{U}_2}}(x) \simeq \begin{cases} 1, & \zeta_1 \geq \frac{\alpha_1}{\alpha_2}, \\ \frac{1}{\Gamma(a+1)} \sum_{m=0}^{\infty} \frac{(-1)^m \left(\frac{1}{b} \sqrt{\frac{x}{G_2 \bar{\gamma} (\alpha_1 - \alpha_2 x)}} \right)^{a+1+m}}{m!(a+1+m)}, & x < \frac{\alpha_1}{\alpha_2}. \end{cases} \quad (34)$$

$$F_{\gamma_{\mathcal{U}_2}}(x) \simeq \frac{1}{\Gamma(a+1)} \sum_{m=0}^{\infty} \frac{(-1)^m \left(\frac{1}{b} \sqrt{\frac{x}{\alpha_2 G_2 \bar{\gamma}}} \right)^{a+1+m}}{m!(a+1+m)}, \quad (35)$$

where m is the expansion order. At high-SNR regime, we can approximate $F_{\gamma_{\mathcal{U}_2}}(x)$ and $F_{\gamma_{\mathcal{U}_2}}(x)$ by ignoring the high value of m (i.e. $m = 0$ is chosen). By combining Equation (32) with Equation (30), the asymptotic BLERs of $\mathcal{U}_2$ can be expressed as

$$\tilde{\varepsilon}_{\mathcal{U}_2}^{x_1} \simeq \begin{cases} 1, & \zeta_2 \geq \frac{\alpha_1}{\alpha_2}, \\ \left(\frac{1}{b} \sqrt{\frac{\zeta_2}{G_2 \bar{\gamma} (\alpha_1 - \alpha_2 \zeta_2)}} \right)^{a+1} \frac{1}{\Gamma(a+1)(a+1)}. & \zeta_2 < \frac{\alpha_1}{\alpha_2}. \end{cases} \quad (36)$$

and

$$\tilde{\varepsilon}_{\mathcal{U}_2}^{x_2} \simeq F_{\gamma_{\mathcal{U}_2}}(\zeta_2) \simeq \frac{\left(\left(\frac{1}{b} \sqrt{\frac{\zeta_2}{\alpha_2 G_2 \bar{\gamma}}} \right) \right)^{a+1}}{\Gamma(a+1)(a+1)}. \quad (37)$$

Finally, by substituting Equations (36) and (37) into Equation (20), we also obtain the asymptotic overall BLERs for decoding x_1 and x_2 at $\mathcal{U}_2$, respectively, as

$$\tilde{\varepsilon}_{\mathcal{U}_2} \simeq \tilde{\varepsilon}_{\mathcal{U}_2}^{x_1} + \tilde{\varepsilon}_{\mathcal{U}_2}^{x_2} - \min \left\{ \tilde{\varepsilon}_{\mathcal{U}_2}^{x_1}, \tilde{\varepsilon}_{\mathcal{U}_2}^{x_2} \right\}. \quad (38)$$




FIGURE 2 The proposed DNN model for BLER prediction at $\mathcal{U}_i$.

4 | DEEP NEURAL NETWORK

4.1 | BLER prediction

In this subsection, we will design a DNN framework to realize the real-time estimation of system performance. While the Monte-Carlo simulations and numerical integration methods require a large amount of runtime for iteration loops to achieve high exact results, which is infeasible for real-time applications (i.e. IoT networks), DNN framework-based efficient performance prediction does not require mathematical derivations. Thus, DNN framework is proposed to simultaneously estimate the BLERs of $\mathcal{U}_i$ with high accuracy, short execution time and low computational complexity toward the real-time prediction for responding to the requirements of different QoS scenarios in modern wireless networks. Furthermore, the influences of such parameters on the network and system performance are analyzed.


■ DNN framework

The DNN model comprises an input layer, an output layer and $\mathbb{Z} - 1$ hidden layers illustrated in Figure 2. In input layer, there are 14 neurons, in which each neuron corresponds to an input parameter value provided in Table 2. In the $\mathbb{Z} - 1$ hidden layers, each layer contains $Q^{(z)}$ neurons for $z = 1, \dots, \mathbb{Z} - 1$ and adopts Sigmoid function as an activation function [34]. It is very important to use in an artificial neural network (ANN) as the activation functions support in learning and making sense of non-linear and complicated mappings between the inputs and corresponding outputs [35]. Because of its wide utilization and simple computation, Sigmoid function is chosen in our proposed DNN. The output layer has two neurons, corresponding to the predicted BLERs of $\mathcal{U}_1$ and $\mathcal{U}_2$ (i.e. $\hat{\varepsilon}_1$ and $\hat{\varepsilon}_2$), respectively. Moreover, we consider a fully connected output layer and no activation functions is used for the typical prediction model. The output layer, $y^{(z)}$ is calculated as [9, Equation (13)]

$$y^{(z)} = g^{(z)} \left[w^{(z)} y^{(z-1)} + b^{(z)} \right], \quad (39)$$

TABLE 2 Parameters for calculating BLERs.

Number	Parameters	Values
1	G_1	1
2	G_2	0.1
3	$\bar{\gamma}$	[0, 20] dB
4	N	2
5	α_1	[0.5; 0.6; 0.8]
6	α_2	[0.5; 0.4; 0.2]
7	L	4
8	$\mathcal{K}$	512 CUs
9	ν	2
10	β_1	256 bits
11	β_2	256 bits
12	d_0	1,
13	d_1	1,
14	d_2	1,

**FIGURE 3** The DNN framework of training and prediction phase.

where $g^{(\cdot)}(x) = \frac{1}{1+e^{-x}}$ is Sigmoid activation function, $w^{(\cdot)}(\cdot)$ and $b^{(\cdot)}(\cdot)$ are the layer of weight and bias. Based on Equation (39), the predicted values of $\hat{\epsilon}_i$ can be expressed as

$$\hat{\epsilon}_i = \mathcal{G}(\mathcal{IN}; \Omega), \quad (40)$$

where $\mathcal{G}(\cdot)$ is the mapping function of the input values $\mathcal{IN}$ with Ω , respectively and can be found from the learning process by the DNN. Here, we set $\Omega = \{w^{(\cdot)}, b^{(\cdot)}\}$ is set of weight and bias.

Next, the DNN framework is divided into two phases of training and prediction shown in Figure 3. In the training phase, the Levenberg–Marquardt algorithm (LMA) is utilized to optimize the model parameters, which based on the dataset throughout the learning process offline. LMA is one of the popular optimization algorithms in neural network training and highly efficient [36, 37]. Depending on learning rate in the backpropagation procedure, the weights and bias are updated

iteratively. As the entire training phase is performed offline, the designed network can significantly reduce computational complexity, deployment costs, and execution time [38]. After completing the training process, the DNN is created in which the achieved results can be used for the online prediction phase whenever any new input is available.

Dataset generation

In order to generate a dataset for training DNN networks, we calculate the average BLERs at $\mathcal{U}_i$, i.e. $\bar{\epsilon}_i$ through the channel and system parameters shown in Table 2 and formulas (17) and (20). These parameters are extract as input variables and $\bar{\epsilon}_i$ as output variables for training samples, respectively. Generally, in the generated dataset $\mathcal{M}$, each sample j is a row vector with $[\text{In}_{[j]}, \text{Out}_{[j]}]$, $j = 1, \dots, \mathcal{M}$, where $\text{In}_{[j]}$ and $\text{Out}_{[j]}$ are the input variable and the corresponding output variable as mentioned above. As a result, the generated dataset $\mathcal{M}$ includes a total of 2000 samples and randomly splits into the training set for learning the prediction model and the test set for checking as observed in Figure 3. Specifically, 70% is used for the training set $\mathcal{M}_{\text{train}}$, while the remaining of percentage of $\mathcal{M}$, i.e. 30% is divided equally for valuation set $\mathcal{M}_{\text{val}}$ and testing set $\mathcal{M}_{\text{tes}}$. For illustrative purposes, we assume the proposed system network is set in the two-dimensional plane. Therefore, the normalized distances of the BS, IRS, $\mathcal{U}_1$ and $\mathcal{U}_2$ are determined as the function of locations as $d_{AB} = \sqrt{(x_A - x_B)^2 + (y_A - y_B)^2}$, where (x_A, x_B) denote the location of the BS, IRS, $\mathcal{U}_1$, and $\mathcal{U}_2$ nodes, respectively. Here, the coordinates of the nodes are set to (0, 0), (1, 0), (0, 1), and (2, 0) and the corresponding distances, i.e. d_0 , d_1 , and d_2 , are presented as Table 2.

Evaluation indices

We utilize two statistical indices as a measure of the effectiveness of the proposed DNN model, i.e. root mean square error (RMSE) and mean absolute percentage error (MAPE) methods, respectively. These performance indices are defined as:

$$\text{RMSE} = \sqrt{\frac{1}{\mathcal{M}_{\text{tes}}} \sum_{j=1}^{\mathcal{M}_{\text{tes}}} \left(\bar{\epsilon}_i^{(j)} - \hat{\epsilon}_i^{(j)} \right)^2}, \quad (41)$$

and

$$\text{MAPE} = \frac{1}{\mathcal{M}_{\text{tes}}} \sum_{j=1}^{\mathcal{M}_{\text{tes}}} \frac{\left| \bar{\epsilon}_i^{(j)} - \hat{\epsilon}_i^{(j)} \right|}{\bar{\epsilon}_i^{(j)}}, \quad (42)$$

where $\bar{\epsilon}_i^{(j)}$ and $\hat{\epsilon}_i^{(j)}$ are the desired BLERs values, (i.e. the initial training values) and the predicted BLERs from the DNN model, respectively.

Remark 3. RMSE and MAPE methods are one of the effective methods to measure the difference between the predicted values and the actual values. Moreover, we note that both of them

are inversely proportional to a number of samples $\mathcal{M}_{tes}$, which mean the smaller the error is, the larger $\mathcal{M}_{tes}$ is. Generally speaking, the best error value is zero for our regression model. Until now, consensus has not been reached on a unified standard metric to evaluate the results of regression models. Therefore, RMSE and MAPE are randomly chosen among other efficient methods for our model. Furthermore, from Equations (41) and (42) paying attention to two methods MAPE gives better results than that of RMSE does [39].

4.2 | The transmit power prediction

The main objective of the proposed system is to meet the QoS requirements of uRLLCs. For uRLLCs, the BLERs of $\mathcal{U}_i$ must be lower than the target value 10^{-5} [40], which requires a high transmit SNR. Because the asymptotic BLERs at $\mathcal{U}_i$ contains sum of multiple terms, it is intractable to calculate them directly. Therefore, we consider allocation power optimization problem by using the average BLERs can be given by

$$\begin{aligned} \min_{P_i} \quad & \bar{\varepsilon}_i(P_i) \\ \text{s.t.} \quad & \alpha_1 P_1 + \alpha_2 P_2 \leq P_0, \\ & \alpha_1 + \alpha_2 = 1, \end{aligned} \quad (43)$$

where P_0 is the total transmit power budget of the system. It is noted that from Equations (17), (25), and (26) the objective function $\bar{\varepsilon}_i(P_i)$, is non-convex function so that the optimization problem in Equations (43) is non-convex. This leads to the optimization problem in Equations (43), which cannot be solved by partial derivative method [41]. To resolve this problem, we built DNN model for predict the transmit power P_i of $\mathcal{U}_i$ under uRLLCs requirements. Similar to the BLERs prediction above, in this subsection we also present the design of DNN model and next conduct the training and testing processes for our model network, which is illustrated in Figure 4a. The model also includes an input layer (containing one neuron $\bar{\varepsilon}_i$), $Z^* - 1$ hidden layers with $Q^{(z^*)}$ neurons on each layer, $z^* = 1, \dots, Z^* - 1$, and an output layer (containing one output neuron $\hat{P}_i$), respectively. In this model, Sigmoid activation function and the LMA algorithm are used as the prediction above. The predicted output values of DNN model with the mapping function $\mathcal{G}^*$, the input values $\bar{\varepsilon}_i$ and set of weight and bias $\Omega^* = \{w^{(z^*)}, b^{(z^*)}\}$, respectively, are obtained as

$$\hat{P}_i = \mathcal{G}^*(\bar{\varepsilon}_i; \Omega^*). \quad (44)$$

The parameters of model are the same parameters shown in Table 2, where we use one of power allocation coefficients, e.g. $\alpha_1 = 0.6$ and $\alpha_2 = 0.4$ for computing the BLERs at $\mathcal{U}_i$ based on Equations (17) and (20). Next, for uRLLCs we only choose $\bar{\varepsilon}_i \leq 10^{-5}$ as the input variables and output variables P_i to perform two of the training and prediction phases presented in Figure 4b. The generated dataset $\mathcal{M}^*$ can be represented as the feature vector values of inputs and outputs, i.e. $[\varepsilon^{(j^*)}, P^{(j^*)}]$, $j^* = 1, \dots, \mathcal{M}^*$.




FIGURE 4 Design of DNN model for the transmit power prediction at $\mathcal{U}_i$.

As a result, samples are generated and also divided in proportion 80% for using the training set, $\mathcal{M}_{train}^*$, while the percent 20% of $\mathcal{M}^*$ splits into equally for valuating set $\mathcal{M}_{val}^*$ and testing set $\mathcal{M}_{tes}^*$.

5 | NUMERICAL RESULTS AND DISCUSSIONS

In this section, the achievable system performances of the proposed model are verified by performing Monte-Carlo simulations. Furthermore, the effectiveness of the designed DNN for predicting BLERs and the transmit power are confirmed by implementing in MATLAB.

5.1 | Performance evaluation


For setting parameters, we also utilize the key simulation parameters provided in Table 2. Unless otherwise stated, as follows: $G_1 = 1$, $G_2 = 0.1$, $\bar{\gamma} = 20\text{dB}$, $\mathcal{K} = 512$ CUs, $\nu = 2$ [42], $\beta_1 = \beta_2 = 256$ bits [33], $N = 2$, $\alpha_1 = [0.5; 0.6; 0.8]$, $\alpha_2 = [0.5; 0.4; 0.2]$, $d_0 = d_1 = d_2 = 1$, and $L = 4$ throughout for this section unless otherwise stated.

Regarding to the DNN simulation, we use the training parameters shown in Table 3.

First, we show the effect of the BLER on average SNR at $\mathcal{U}_1$ and $\mathcal{U}_2$ with three cases of power allocation coefficients, i.e. $\alpha_1 = \alpha_2 = 0.5$, $\alpha_1 = 0.6$, $\alpha_2 = 0.4$, and $\alpha_1 = 0.8$, $\alpha_2 = 0.2$, respectively. In Figure 5, we observe that the BLERs for $\mathcal{U}_1$ and $\mathcal{U}_2$ decrease in the medium and high average SNR ranges when the transmit power allocation increases for all users. As observed, the contrast BLER between the power allocation coefficient of α_1 for $\mathcal{U}_1$ and the value α_2 for $\mathcal{U}_1$. Specifically, the larger value α_1 is, the lower the BLER at $\mathcal{U}_1$ has, accordingly. For $\mathcal{U}_2$, the lowest BLER achieves when the value of $\alpha_2 = 0.4$.

TABLE 3 Training parameters for DNN to the BLERs prediction.



Training parameters	Values
A number of hidden layers	4 layers
A number of neuron in the hidden layers	100 neurons
Learning rate	10^{-3}
Activation function	Sigmoid
Epoch for training phase	1000 epochs

**FIGURE 5** The effect of average SNR on the average BLERs at $\mathcal{U}_1$ and $\mathcal{U}_2$ with three cases of power allocation coefficients, i.e. $\alpha_1 = \alpha_2 = 0.5$, $\alpha_1 = 0.6, \alpha_2 = 0.4$, and $\alpha_1 = 0.8, \alpha_2 = 0.2$.

However, when $\alpha_1 = \alpha_2 = 0.5$ the BLER of α_2 decrease but the BLER of $\mathcal{U}_2$ obtains the highest of the values of α_1 . Consequently, to ensure the energy source for both $\mathcal{U}_1$ and $\mathcal{U}_2$, the power allocation coefficient $\alpha_1 = 0.6$ and $\alpha_2 = 0.4$ are chosen for the later figures. Importantly, the predicted results using DNN completely coincide with the results of theoretical analysis at all the SNR values for $\mathcal{U}_1$ and $\mathcal{U}_2$. At the high-SNR, the simulation results match incompletely with two results of theoretical analysis and DNN simulation because the BLER of $\mathcal{U}_2$ has the approximative form. This clearly shows that the efficiency of DNN compared to the simulation results.

Figure 6 investigates the effect of blocklength $\mathcal{K}$ on the BLER at $\mathcal{U}_1$ and $\mathcal{U}_2$. We see that the average BLERs at all users decrease, when blocklength increases in two of average SNRs as $\bar{\gamma} = 15$ dB and $\bar{\gamma} = 20$ dB. Note that the BLER of $\mathcal{U}_2$ is smaller than that of $\mathcal{U}_1$ at all the value of $\bar{\gamma}$. This means that the performance of $\mathcal{U}_2$ is better than the performance of $\mathcal{U}_1$ in spite of less power allocation. However, there is the trade-off between large blocklength and high latency as shown in Figure 8. For example, for $\mathcal{U}_2$ can ensure uRLLCs (the average BLER of 10^{-5}), $\bar{\gamma} = 20$ dB and the blocklength of 600 CUs will be chosen.

Next, Figure 7 depicts the effect of passive reflecting elements L on the average BLER of $\mathcal{U}_2$ with three levels of $\bar{\gamma}$ as 5, 10, and 15 dB. As observed, the BLER of $\mathcal{U}_2$ decrease significantly when increasing L and $\bar{\gamma}$. Since the limitation of $\bar{\gamma}$, we

**FIGURE 6** The effect of blocklength $\mathcal{K}$ on the average BLERs at $\mathcal{U}_1$ and $\mathcal{U}_2$ with $\alpha_1 = 0.6$ and $\alpha_2 = 0.4$.**FIGURE 7** The effect of passive reflecting elements L on the average BLER of $\mathcal{U}_2$.

can increase appropriately L for improving the performance of $\mathcal{U}_2$.

Figure 8 shows the influence of the latency and reliability on the blocklength at $\mathcal{U}_1$ and $\mathcal{U}_2$ in typical two levels of average SNR, as $\bar{\gamma} = 15$ dB and $\bar{\gamma} = 20$ dB. As seen, the latency and reliability of $\mathcal{U}_2$ are better than those of $\mathcal{U}_1$ for two cases of SNRs, i.e. 15 and 20 dB. Noted that increasing $\mathcal{K}$ leads to the latency for users increase, respectively. In particular, at $\mathcal{K} = 300$ CUs the latency of two users gains the best values, e.g. $\tau \approx 300$ CUs with $\bar{\gamma} = 20$ dB at $\mathcal{U}_2$ and the reliability becomes saturated when $\mathcal{K} = 400$ CUs. This is reasonable with the results as shown in Figure 6 because of the slow decrease of BLERs from $\mathcal{K} = 400$ CUs. Therefore, as assumed if we choose $\mathcal{K} = 600$ CUs for a duration of 3μ , the system will suffer from the latency of $1.8 ms$ which satisfies the delay requirement of uRLLCs for serving tactile Internet [43].

Figure 9 depicts two of methods for evaluating the effectiveness of the DNN model, i.e. RMSE and MAPE for $\mathcal{U}_1$ and $\mathcal{U}_2$. As observed, both of the methods decrease when the




FIGURE 8 The influence of the latency and reliability on the blocklength K at U_1 and U_2 in two cases of average SNR, i.e. $\bar{\gamma} = 15$ dB and $\bar{\gamma} = 20$ dB, respectively.




FIGURE 9 RMSE and MAPE versus the number of testing samples.

number of samples M increases. Specifically, the RMSE and MAPLE at U_1 are smaller than those of U_2 which show the predicted output of U_1 is more accurate. This mean that the exact closed-form BLER of U_1 is simply for calculating more than the complex form of BLER of U_2 . Moreover, the predicted results of MAPLE are better than that of RMSE with the same hidden layers for all users. This prediction matches completely with the theoretical results in Equations (41) and (42). However, the RMSE and MAPLE values obtain under 10^{-5} on the checked dataset in which the error is so small and possible for accurately predicting the designed DNN model.

Eventually, we evaluate the execution time of the DNN prediction results compared with the results of theoretical analysis and simulation in Table 4. We can see that the DNN prediction takes a very short execution time compared the others which prove the excellent efficiency of DNN. For example, the prediction BLERs of DNN scheme require a short duration as 0.002797 s and 0.002962 s for U_1 and U_2 while the simulation wastes 5.629326 and 25.463482 s, respectively. The reason why the simulation results take longer is because of the computa-

TABLE 4 Comparison execution time of the theoretical and the simulation results versus the proposed DNN network results at U_1 and U_2 .

Scenarios	Execution time (s)
Analysis - U_1	1.336408 (s)
Analysis - U_2	6.390332 (s)
Simulation - U_1	5.629326 (s)
Simulation - U_2	25.463482 (s)
DNN - U_1	0.002797 (s)
DNN - U_2	0.002962 (s)




FIGURE 10 The average BLER versus the transmit power allocation at U_2 with different layers.

tional complexity of BLERs. Note that, for DNN prediction the network scales also affect to the prediction time, e.g. the execution time of U_2 is about 5.0539224 s longer than that of U_1 .

5.2 | The transmit power prediction

In this subsection, the results of power allocation prediction for U_2 based on the proposed DNN model. The experiments for the DNN model are implemented on Matlab and the training parameters are similar to the prediction of BLER scheme, i.e. 100 neurons per layer, 1000 epochs for training phase, learning rate of 10^{-3} and Sigmoid activation as shown in Table 3. Especially, the input values of average BLER for training phase are chosen under 10^{-5} . In this scheme, dataset is generated about 2000 samples divided into three percentage of dataset as 80% for the training, 20% for the validation and the testing. First, we demonstrate the effect of average BLER on average SNR which considered as the transmit power P with different hidden layers as in Figure 10. As observed, the average BLERs of U_2 decrease significantly, when P increases for all of the hidden layers. Concretely, the prediction results by DNN model match completely with the desired results (solid line) over two hidden layers.




FIGURE 11 RMSE and MAPLE of DNN model with multiple hidden layers and a number of samples.

TABLE 5 Comparison execution time of the proposed DNN model with multiple hidden layers and the RMSE and MAPLE.

Scenarios	Execution time (s)	RMSE	MAPLE
DNN – 1 layer	0.007380 (s)	$1.805 \cdot 10^{-8}$	$6.033 \cdot 10^{-5}$,
DNN – 2 layer	0.007694 (s)	$1.204 \cdot 10^{-20}$,	$4.3 \cdot 89 \cdot 10^{-16}$,
DNN – 4 layer	0.01024 (s)	$1.204 \cdot 10^{-20}$,	$4.3 \cdot 89 \cdot 10^{-16}$,
DNN – 10 layer	0.010244 (s),	$1.204 \cdot 10^{-20}$,	$4.3 \cdot 89 \cdot 10^{-16}$,

This leads to low values of RMSE and MAPLE as illustrated in Figure 11.

We know that for multiple hidden layers the DNN model can be capable of generating large dataset, and result in large network capacity, while the DNN with 1 layer cannot learn the complicated patterns in a large dataset. Therefore, the prediction results with 1 layer is not as accurate as the results in the bigger hidden layers. However, we should be conservatively considered when increasing the number of hidden layers because this will affect the system execution time as illustrated in Table 5.

To be time-efficient solutions, the optimal hidden layer for our DNN model can be chosen as 4 layers to achieve short time in the considered system setup phase. Moreover, from Figure 10, we note that for the average BLER of 10^{-5} , the power system is allocated about 21 dB. This mean that the transmit power for $\mathcal{U}_2$ and $\mathcal{U}_1$ is 8.4 and 12.6 dB, respectively.

6 | CONCLUSIONS

In this paper, we have investigated SPCs for IRS-assisted NOMA systems. The proposed NOMA network is beneficial in the context of limited transmit power and the low spectrum efficiency to achieve uRLLCs. Besides that, the beamforming techniques are utilized at the BS to provide the required qual-

ity of service for all users. In the finite-blocklength regime, the approximated average BLERs for users are derived and from which the e2e latency and the system reliability are also considered to provide a performance overview of both ultra-reliability and low-latency. Subsequently, the asymptotic average BLERs are conducted to get more insights into the system design in the high-SNR regime. Furthermore, we developed a DNN framework for the BLERs evaluation for users towards real-time and the allocation power estimation for users with a low execution time under the uRLLCs constraints. The results have shown that theoretical analysis results, the conventional simulation results (by Monte-Carlo simulation) and the DNN results for the BLERs prediction at users are well matched with each other. Especially, the estimated results of DNN's transmit power allocation are in perfect agreement with the desired training results with the low value of two error indices, i.e. RMSE and MAPLE. Most importantly, our designed DNN method obtains some advantages such as in high accuracy, low execution time, and decreased computational complexity.

AUTHOR CONTRIBUTIONS

Nguyen Thi Yen Linh: Writing - original draft. Pham Ngoc Son: Writing - review and editing. Vo Nguyen Quoc Bao: Discussing to propose ideas, collaborating on drafting, and approving the draft for submission.

ACKNOWLEDGEMENTS

This work belongs to the project grant No: T2022-02NCS funded by Ho Chi Minh City University of Technology and Education, Vietnam.

CONFLICT OF INTEREST

The authors declare no conflict of interest.

DATA AVAILABILITY STATEMENT

The data that support the findings of this study are available from the corresponding author upon reasonable request.

ORCID

Vo Nguyen Quoc Bao  <https://orcid.org/0000-0002-1791-6467>

REFERENCES

1. Sutton, G.J., Zeng, J., Liu, R.P., Ni, W., Nguyen, D.N., Jayawickrama, B.A., Huang, X., Abolhasan, M., Zhang, Z., Dutkiewicz, E., et al.: Enabling technologies for ultra-reliable and low latency communications: from PHY and MAC layer perspectives. *IEEE Commun. Surv. Tutorials* 21(3), 2488–2524 (2019)
2. Shirvanimoghaddam, M., Mohammadi, M.S., Abbas, R., Minja, A., Yue, C., Matuz, B., Han, G., Lin, Z., Liu, W., Li, Y., et al.: Short block-length codes for ultra-reliable low latency communications. *IEEE Commun. Mag.* 57(2), 130–137 (2018)
3. Durisi, G., Koch, T., Popovski, P.: Toward massive, ultrareliable, and low-latency wireless communication with short packets. *Proc. IEEE* 104(9), 1711–1726 (2016)
4. Liu, Y., Zhang, S., Mu, X., Ding, Z., Schober, R., Al-Dhahir, N., Hossain, E., Shen, X.: Evolution of NOMA toward next generation multiple access (NGMA) for 6G. *IEEE J. Sel. Areas Commun.* 40(4), 1037–1071 (2022)

5. Dai, L., Wang, B., Yuan, Y., Han, S., Chih-Lin, I., Wang, Z.: Non-orthogonal multiple access for 5G: solutions, challenges, opportunities, and future research trends. *IEEE Commun. Mag.* 53(9), 74–81 (2015)
6. Tang, W., Chen, M.Z., Chen, X., Dai, J.Y., Han, Y., Di Renzo, M., Zeng, Y., Jin, S., Cheng, Q., Cui, T.J.: Wireless communications with reconfigurable intelligent surface: path loss modeling and experimental measurement. *IEEE Trans. Wireless Commun.* 20(1), 421–439 (2020)
7. Liu, Y., Liu, X., Mu, X., Hou, T., Xu, J., Di Renzo, M., Al-Dhahir, N.: Reconfigurable intelligent surfaces: principles and opportunities. *IEEE Commun. Surv. Tutorials* 23(3), 1546–1577 (2021)
8. Nguyen, T.-V., Tran, T.-N., Shim, K., Huynh-The, T., An, B.: A deep-neural-network-based relay selection scheme in wireless-powered cognitive IoT networks. *IEEE Internet Things J.* 8(9), 7423–7436 (2020)
9. Zhang, C., Patras, P., Haddadi, H.: Deep learning in mobile and wireless networking: a survey. *IEEE Commun. Surv. Tutorials* 21(3), 2224–2287 (2019)
10. Sun, X., Yan, S., Yang, N., Ding, Z., Shen, C., Zhong, Z.: Short-packet downlink transmission with non-orthogonal multiple access. *IEEE Trans. Wireless Commun.* 17(7), 4550–4564 (2018)
11. Yu, Y., Chen, H., Li, Y., Ding, Z., Vucetic, B.: On the performance of non-orthogonal multiple access in short-packet communications. *IEEE Commun. Lett.* 22(3), 590–593 (2017)
12. Zheng, J., Zhang, Q., Qin, J.: Average block error rate of downlink noma short-packet communication systems in Nakagami- m fading channels. *IEEE Commun. Lett.* 23(10), 1712–1716 (2019)
13. Tran, D.-D., Sharma, S.K., Chatzinotas, S., Woungang, I., Ottersten, B.: Short-packet communications for MIMO NOMA systems over Nakagami- m fading: BLER and minimum blocklength analysis. *IEEE Trans. Veh. Technol.* 70(4), 3583–3598 (2021)
14. Vu, T.-H., Nguyen, T.-V., da Costa, D.B., Kim, S.: Intelligent reflecting surface-aided short-packet non-orthogonal multiple access systems. *IEEE Trans. Veh. Technol.* 71(4), 4500–4505 (2022)
15. Hashemi, R., Ali, S., Mahmood, N., Latva-aho, M.: Average rate and error probability analysis in short packet communications over RIS-aided URLLC systems. *IEEE Trans. Veh. Technol.* 70(10), 10320–10334 (2021)
16. Nguyen, T.-V., Nguyen, V.-D., da Costa, D.B., An, B.: Short-packet communications in multi-hop WPINs: performance analysis and deep learning design. In: 2021 IEEE Global Communications Conference (GLOBECOM), pp. 1–6. IEEE, Piscataway, NJ (2021)
17. Vu, T.-H., Nguyen, T.-V., Nguyen, T.-T., Kim, S.: Performance analysis and deep learning design of wireless powered cognitive NOMA IoT short-packet communications with imperfect CSI and SIC. *IEEE Internet Things J.* 9(13), 10464–10479 (2021)
18. Balanis, C.A.: *Antenna Theory: Analysis and Design*. Wiley, New York (2016)
19. Wu, Q., Zhang, R.: Intelligent reflecting surface enhanced wireless network via joint active and passive beamforming. *IEEE Trans. Wireless Commun.* 18(11), 5394–5409 (2019)
20. Yang, Y., Zheng, B., Zhang, S., Zhang, R.: Intelligent reflecting surfaces OFDM: protocol design and rate maximization. *IEEE Trans. Commun.* 68(7), 4522–4535 (2020)
21. Chen, J., Liang, Y.-C., Cheng, H.V., Yu, W.: Channel estimation for reconfigurable intelligent surface aided multi-user MIMO systems. *arXiv:1912.03619*, 2019.
22. Taha, A., Alrabeiah, M., Alkhateeb, A.: Enabling large intelligent surfaces with compressive sensing and deep learning. *IEEE Access* 9, 44304–44321 (2021)
23. Papoulis, A., Pillai, S.: *Unnikrishna: Probability. Random Variables and Stochastic Processes*, Fourth Edition. McGraw-Hill, New York (2002)
24. Laneman, J.N., Tse, D.N., Wornell, G.W.: Cooperative diversity in wireless networks: efficient protocols and outage behavior. *IEEE Trans. Inf. Theory* 50(12), 3062–3080 (2004)
25. Dao, T.-T.T., Son, P.N.: Multi-constraint two-way underlay cognitive network using reconfigurable intelligent surface. *Wireless Networks* 28(5), 2017–2030 (2022)
26. Basar, E., Di Renzo, M., De Rosny, J., Debbah, M., Alouini, M.-S., Zhang, R.: Wireless communications through reconfigurable intelligent surfaces. *IEEE Access* 7, 116 753–116 773 (2019)
27. Yang, W., Durisi, G., Koch, T., Polyanskiy, Y.: Quasi-static multiple-antennafading channels at finite blocklength. *IEEE Trans. Inf. Theory* 60(7), 4232–4265 (2014)
28. Polyanskiy, Y., Poor, H.V., Verdú, S.: Channel coding rate in the finite blocklength regime. *IEEE Trans. Inf. Theory* 56(5), 2307–2359 (2010)
29. López, O.L.A., Fernández, E.M.G., Souza, R.D., Alves, H.: Ultra-reliable cooperative short-packet communications with wireless energy transfer. *IEEE Sens. J.* 18(5), 2161–2177 (2018)
30. Steele, J.M.: *The Cauchy-Schwarz Master Class: An Introduction to the Art of Mathematical Inequalities*. Cambridge University Press, Cambridge (2004)
31. Chen, H., Abbas, R., Cheng, P., Shirvanimoghaddam, M., Hardjawana, W., Bao, W., Li, Y., Vucetic, B.: Ultra-reliable low latency cellular networks: use cases, challenges and approaches. *IEEE Commun. Mag.* 56(12), 119–125 (2018)
32. Makki, B., Svensson, T., Zorzi, M.: Finite block-length analysis of the incremental redundancy HARQ. *IEEE Wireless Commun. Lett.* 3(5), 529–532 (2014)
33. Linh, N.T.Y., Tu, N.H., Son, P.N., Bao, V.N.Q.: Dual-hop relaying networks for short-packet URLLC: Performance analysis and optimization. *J. Commun. Networks* 24(4), 408–418 (2022)
34. Sharma, S., Sharma, S., Athaiya, A.: Activation functions in neural networks. *Int. J. Eng. Appl. Sci. Technol.* 4(12), 310–316 (2020)
35. Sofotasios, P.C., Freear, S.: Novel expressions for the marcum and one dimensional Q-functions. In: 2010 7th International Symposium on Wireless Communication Systems, pp. 736–740 (2010)
36. Reynaldi, A., Lukas, S., Margaretha, H.: Backpropagation and Levenberg-Marquardt algorithm for training finite element neural network. In: 2012 Sixth UKSim/AMSS European Symposium on Computer Modeling and Simulation. Malta: pp. 89–94. IEEE, Piscataway, NJ (2012)
37. Hagan, M.T., Menhaj, M.B.: Training feedforward networks with the marquardt algorithm. *IEEE Trans. Neural Networks* 5(6), 989–993 (1994)
38. Ho, C.D., Nguyen, T.-V., Huynh-The, T., Nguyen, T.-T., da Costa, D.B., An, B.: Short-packet communications in wireless-powered cognitive IoT networks: performance analysis and deep learning evaluation. *IEEE Trans. Veh. Technol.* 70(3), 2894–2899 (2021)
39. Chicco, D., Warrens, M.J., Jurman, G.: The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peer J. Comput. Sci.* 7, e623 (2021)
40. Durisi, G., Koch, T., Östman, J., Polyanskiy, Y., Yang, W.: Short-packet communications over multiple-antenna Rayleigh-fading channels. *IEEE Trans. Commun.* 64(2), 618–629 (2015)
41. Boris, N.M.N., Mordukhovich, S.: *Applications to Optimization and Location Problems*. Springer, Cham (2014)
42. Goldsmith, A.: *Wireless Communications*. Cambridge University Press, Cambridge (2005)
43. She, C., Sun, C., Gu, Z., Li, Y., Yang, C., Poor, H.V., Vucetic, B.: A tutorial on ultrareliable and low-latency communications in 6G: Integrating Domain Knowledge into Deep Learning. *Proc. IEEE* 109(3), 204–246 (2021)
44. Gradshteyn, I.S., Ryzhik, I.M.: *Table of Integrals, Series, and Products*. Academic Press, San Diego, CA (2014)
45. Abramowitz, M., Stegun, I.A.: *Handbook of mathematical functions with formulas, graphs, and mathematical tables*. Dover Publications, Mineola, NY (1972)

How to cite this article: Linh, N.T.Y., Son, P.N., Bao, V.N.Q.: Intelligent reflecting surface-assisted beamforming-NOMA networks for short-packet communications: Performance analysis and deep learning approach. *IET Commun.* 17, 1940–1954 (2023). <https://doi.org/10.1049/cmu2.12667>

APPENDIX A

Proof of Lemma 1. According to Equation (16), the average BLER at $\mathcal{U}_1$ can be expressed as

$$\bar{\epsilon}_{\mathcal{U}_1} \approx v_1 \sqrt{\mathcal{K}} \int_{\rho_{1L}}^{\rho_{1H}} F_{\gamma_{\mathcal{U}_1}^{\mathcal{X}_1}}(\gamma) d\gamma. \quad (\text{A1})$$

By substituting Equation (10) into Equation (A1), we obtain

$$\bar{\epsilon}_{\mathcal{U}_1}(\mathcal{X}) = \begin{cases} v_1 \sqrt{\mathcal{K}} \int_{\rho_{1L}}^{\rho_{1H}} dx, & \frac{\alpha_1}{\alpha_2} \leq \rho_{1L}, \\ v_1 \sqrt{\mathcal{K}} \mathcal{I}_1 + v_1 \sqrt{\mathcal{K}} \int_{\alpha_1/\alpha_2}^{\rho_{1H}} dx, & \rho_{1L} < \frac{\alpha_1}{\alpha_2} < \rho_{1H}, \\ v_1 \sqrt{\mathcal{K}} \mathcal{I}_2, & \frac{\alpha_1}{\alpha_2} \geq \rho_{1H}, \end{cases} \quad (\text{A2})$$

where

$$\mathcal{I}_1 = \int_{\rho_{1L}}^{\alpha_1/\alpha_2} \exp\left(-\lambda_0 \frac{x}{G_1 \bar{\gamma}(\alpha_1 - \alpha_2 x)}\right) dx, \quad (\text{A3})$$

and

$$\mathcal{I}_2 = \int_{\rho_{1L}}^{\rho_{1H}} \exp\left(-\lambda_0 \frac{x}{G_1 \bar{\gamma}(\alpha_1 - \alpha_2 x)}\right) dx. \quad (\text{A4})$$

We change the variable of x in Equations (A3) and (A4) by setting $y = \alpha_1 - \alpha_2 x$. By doing so, Equations (A3) and (A4) can be rewritten as

$$\mathcal{I}_1 = \frac{1}{\alpha_2} \exp\left(\frac{\lambda_0}{\alpha_2 G_1 \bar{\gamma}}\right) \times \int_0^{\alpha_1 - \alpha_2 \rho_{1L}} \exp\left(-\lambda_0 \frac{\alpha_1}{G_1 \alpha_2 \bar{\gamma} y}\right) dy, \quad (\text{A5})$$

$$\mathcal{I}_2 = \frac{1}{\alpha_2} \exp\left(\frac{\lambda_0}{\alpha_2 G_1 \bar{\gamma}}\right) \times \int_{\alpha_1 - \alpha_2 \rho_{1H}}^{\alpha_1 - \alpha_2 \rho_{1L}} \exp\left(-\lambda_0 \frac{\alpha_1}{G_1 \alpha_2 \bar{\gamma} y}\right) dy. \quad (\text{A6})$$

Next, by calculating the integral in Equations (A5) and (A6) and then replacing $\mathcal{I}_1$ and $\mathcal{I}_2$ into Equation (A2). After some manipulations, we can obtain **Lemma 1**, which also completes the proof. $\square$

APPENDIX B

Proof of Lemma 2. The aid of Equations (11), (12), and (16), the average BLERs of $\mathcal{U}_2$ in decoding $\mathcal{X}_1$ and $\mathcal{X}_2$ can be

derived as

$$\bar{\epsilon}_{\mathcal{U}_2}^{\mathcal{X}_1} = \begin{cases} v_2 \sqrt{\mathcal{K}}(\rho_{2H} - \rho_{2L}), & \frac{\alpha_1}{\alpha_2} \leq \rho_{2L}, \\ v_2 \sqrt{\mathcal{K}} \left[(\rho_{2H} - \rho_{2L}) - \frac{2}{\Gamma(a+1)} \mathcal{I}_3 \right], & \rho_{2L} < \frac{\alpha_1}{\alpha_2} < \rho_{2H}, \\ v_2 \sqrt{\mathcal{K}} \left[(\rho_{2H} - \rho_{2L}) - \frac{2}{\Gamma(a+1)} \mathcal{I}_4 \right], & \frac{\alpha_1}{\alpha_2} \geq \rho_{2H}, \end{cases} \quad (\text{A7})$$

where

$$\mathcal{I}_3 = v_2 \sqrt{\mathcal{K}} \int_{\rho_{2L}}^{\frac{\alpha_1}{\alpha_2}} \Gamma\left(a+1, \frac{1}{b} \sqrt{\frac{x}{G_2 \bar{\gamma}(\alpha_1 - \alpha_2 x)}}\right) dx, \quad (\text{A8})$$

$$\mathcal{I}_4 = v_2 \sqrt{\mathcal{K}} \int_{\rho_{2L}}^{\rho_{2H}} \Gamma\left(a+1, \frac{1}{b} \sqrt{\frac{x}{G_2 \bar{\gamma}(\alpha_1 - \alpha_2 x)}}\right) dx, \quad (\text{A9})$$

and

$$\bar{\epsilon}_{\mathcal{U}_2}^{\mathcal{X}_2} = v_2 \sqrt{\mathcal{K}} \left((\rho_{2H} - \rho_{2L}) + \underbrace{\int_{\rho_{2L}}^{\rho_{2H}} \frac{\Gamma\left(a+1, \frac{1}{b} \sqrt{\frac{x}{\alpha_2 G_2 \bar{\gamma}}}\right)}{\Gamma(a+1)} dx}_{\mathcal{I}_5} \right). \quad (\text{A10})$$

We set the integral $\mathcal{I}_5$ as marked in Equation (A10) as follows:

$$\mathcal{I}_5 = \int_{\rho_{2L}}^{\rho_{2H}} \frac{\Gamma\left(a+1, \frac{1}{b} \sqrt{\frac{x}{\alpha_2 G_2 \bar{\gamma}}}\right)}{\Gamma(a+1)} dx. \quad (\text{A11})$$

By employing the integral in Equation (A11) and later replacing the result of $\mathcal{I}_5$ into Equation (A10), we obtain

$$\bar{\epsilon}_{\mathcal{U}_2}^{\mathcal{X}_2} = v_2 \sqrt{\mathcal{K}} \left[(\rho_{2H} - \rho_{2L}) - \frac{2}{\Gamma(a+1)} (\Delta(\sqrt{\rho_{2H}}) - \Delta(\sqrt{\rho_{2L}})) \right], \quad (\text{A12})$$

where

$$\begin{aligned} \Delta(x) &= \frac{x^2}{2} \Gamma\left(a+1, \frac{x}{b\sqrt{\alpha_2 G_2 \bar{\gamma}}}\right) - \frac{x^{a+2}}{(b\sqrt{\alpha_2 G_2 \bar{\gamma}})^a} \\ &\quad \times \frac{e^{\frac{-x}{b\sqrt{\alpha_2 G_2 \bar{\gamma}}}}}{2} - \frac{(a+2)}{2 \left(\frac{1}{b\sqrt{\alpha_2 G_2 \bar{\gamma}}}\right)^2} \Gamma\left(a+2, \frac{x}{b\sqrt{\alpha_2 G_2 \bar{\gamma}}}\right). \end{aligned} \quad (\text{A13})$$

Next, by setting $\mathcal{X} = \frac{1}{b} \sqrt{\frac{x}{G_2 \bar{\gamma}(\alpha_1 - \alpha_2 x)}}$, the integral of Equations (A8) and (A9) can be respectively simplified as follows:

$$I_3 = v_2 \sqrt{\mathcal{K}} \int_{\mathfrak{I}_L}^{+\infty} \Gamma(a+1, \mathfrak{z}) \frac{2\mathfrak{z}}{\mathcal{Z}\alpha_2^2(\mathfrak{z}^2 + \chi)^2} d\mathfrak{z}, \quad (\text{A14})$$

$$I_4 = v_2 \sqrt{\mathcal{K}} \int_{\mathfrak{I}_L}^{\mathfrak{I}_H} \Gamma(a+1, \mathfrak{z}) \frac{2\mathfrak{z}}{\mathcal{Z}\alpha_2^2(\mathfrak{z}^2 + \chi)^2} d\mathfrak{z}, \quad (\text{A15})$$

where

$$\mathfrak{I}_L = \frac{1}{b} \sqrt{\frac{\rho_{2L}}{G_2 \bar{\gamma}(\alpha_1 - \alpha_2 \rho_{2L})}}, \quad (\text{A16})$$

$$\mathfrak{I}_H = \frac{1}{b} \sqrt{\frac{\rho_{2H}}{G_2 \bar{\gamma}(\alpha_1 - \alpha_2 \rho_{2H})}}, \quad (\text{A17})$$

$$\chi = \frac{1}{\mathcal{Z}\alpha_2}, \quad (\text{A18})$$

$$\mathcal{Z} = G_2 \bar{\gamma} b^2. \quad (\text{A19})$$

Moreover, we apply integration by parts through setting $u = \Gamma(a+1, \mathfrak{z})$ and $dv = \frac{2\mathfrak{z}}{(\mathfrak{z}^2 + \chi)^2}$. By doing so, Equations (A14) and (A15) can be analytically obtained as

$$I_3 = \left(\frac{\alpha_1}{\mathcal{Z}\alpha_2^2} \right) \frac{\Gamma(a+1, \mathfrak{I}_L)}{\mathfrak{I}_L^2 + \chi} - \underbrace{\int_{\mathfrak{I}_L}^{+\infty} \frac{\mathfrak{z}^a e^{-\mathfrak{z}}}{\mathfrak{z}^2 + \chi} d\mathfrak{z}}_{\Psi_1}. \quad (\text{A20})$$

$$I_4 = \frac{\alpha_1}{\mathcal{Z}\alpha_2^2} \left[\frac{\Gamma(a+1, \mathfrak{I}_L)}{\mathfrak{I}_L^2 + \chi} - \frac{\Gamma(a+1, \mathfrak{I}_H)}{\mathfrak{I}_H^2 + \chi} \right] - \underbrace{\int_{\mathfrak{I}_L}^{\mathfrak{I}_H} \frac{\mathfrak{z}^a e^{-\mathfrak{z}}}{\mathfrak{z}^2 + \chi} d\mathfrak{z}}_{\Psi_2}. \quad (\text{A21})$$

Especially, Ψ_1 and Ψ_2 as marked in Equations (A20) and (A21) are expressed as

$$\Psi_1 = \int_{\mathfrak{I}_L}^{+\infty} \frac{\mathfrak{z}^a e^{-\mathfrak{z}}}{\mathfrak{z}^2 + \chi} d\mathfrak{z}, \quad (\text{A22})$$

and

$$\Psi_2 = \int_{\mathfrak{I}_L}^{\mathfrak{I}_H} \frac{\mathfrak{z}^a e^{-\mathfrak{z}}}{\mathfrak{z}^2 + \chi} d\mathfrak{z}. \quad (\text{A23})$$

By setting $u = e^{-\mathfrak{z}}$ and applying again the integration by parts method, Equations (A22) and (A23) can be analytically obtained as

$$\Psi_1 = \frac{1}{\chi(1+a)} \left[\mathfrak{I}_L^{\chi(1+a)} e^{-\mathfrak{I}_L} + \int_{\mathfrak{I}_L}^{\infty} \mathfrak{z}^{\chi(1+a)-1} e^{-\mathfrak{z}} \delta(\mathfrak{z}) d\mathfrak{z} \right], \quad (\text{A24})$$

and

$$\Psi_2 = \frac{1}{\chi(1+a)} \left[\mathfrak{I}_H^{\chi(1+a)} e^{-\mathfrak{I}_H} - \mathfrak{I}_L^{\chi(1+a)} e^{-\mathfrak{I}_L} + \int_{\mathfrak{I}_L}^{\mathfrak{I}_H} \mathfrak{z}^{\chi(1+a)-1} e^{-\mathfrak{z}} \delta(\mathfrak{z}) d\mathfrak{z} \right], \quad (\text{A25})$$

where $\delta(\mathfrak{z}) = {}_2F_1(1, \frac{1+a}{2}; 1 + \frac{1+a}{2}; -\frac{\mathfrak{z}^2}{\chi})$ with ${}_2F_1(\cdot, \cdot; \cdot; \cdot)$ is the Gauss hypergeometric function [44, Equation (9.14.2)].

According to [45, Equation (15.1.1a)], the integral in Equations (A24) and (A25) are divergence. It is difficult to obtain directly the closed-form mathematical expressions for this integral. Here, based on Matlab software, the authors obtain the approximated values of Ψ_1 and Ψ_2 , respectively. Finally, by substituting the results in Equations (A24) and (A25) into Equations (A20) and (A21), we attain the desired results as in **Lemma 2**. The proof is concluded. $\square$

Dual-hop Relaying Networks for Short-Packet URLLCs: Performance Analysis and Optimization

Nguyen Thi Yen Linh, Ngo Hoang Tu, Pham Ngoc Son, and Vo Nguyen Quoc Bao

Abstract—This paper investigates short-packet communications for the dual-hop decode-and-forward relaying system to facilitate ultra-reliable and low-latency communications. In this system, based on the transmit antenna selection and partial relay selection techniques, a selected relay having the highest received signal-to-noise ratio (SNR) serves as a forwarder to support the unavailable direct link between the source and destination, whereas a maximum ratio combining technique is leveraged at the destination to achieve the highest diversity gain. Approximated expressions of end-to-end (e2e) block error rates (BLERs) are derived over quasi-static Rayleigh fading channels and the finite-blocklength regime. To gain more insights about the performance behavior in the high-SNR regime, we provide the asymptotic analysis with two approaches, from which the qualitative conclusion based on the diversity order is made. Furthermore, the power allocation and relay location optimization problems are also considered to minimize the asymptotic e2e BLER under the configuration constraints. Our analysis is verified through Monte-Carlo simulations, which yield the system parameters' impact on the system performance.

Index Terms—Optimization, relay network, short-packet communications, ultra-reliable and low-latency.

I. INTRODUCTION

IN the dramatical development of emerging communication systems, the technologies that support the fifth-generation and beyond networks are positive factors in realizing the era of the Internet of things and hyperlinked society by enabling enhanced mobile broadband, massive machine-type communications, and ultra-reliable low-latency Communications (uRLLCs) [1]–[3]. Known as one of the key services, uRLLC requires the reliability more than 99.9999%, which refers to packet error rate lower than 10^{-5} [4], [5], and latency around 1 – 10 ms [6]. Inspired by these requirements, short-packet communications (SPCs) with finite-blocklength have become a potential solution, where some pioneering frameworks on SPCs have been considered in the literature. For example,

Polyanskiy *et al.* in [7] explored the approximation of the maximum achievable rates as a function of error probability and blocklength. Meanwhile, Yang *et al.* in [8] determined the appropriate blocklength for the best ergodic capacity. Motivated by the pioneering works, the outstanding performance and capability of SPCs to support the aforementioned uRLLC requirements has been well confirmed with the integrations of various technologies and network models, such as the non-orthogonal multiple access [9], energy harvesting [6], and the multiple-input multiple-output (MIMO) systems [10], etc.

Besides that, the relaying system is known as an effective solution to extend coverage, limit transmit power support, and improve the efficiency of data transmission by using intermediate relaying nodes to support information transmission and reception over short distances [11]. Recently, many scientists have paid more attention to work on SPCs in relay networks to enhance system performance and fulfill service requirements for 5G and beyond networks. Specifically, Yifan Gu *et al.* in [12] compared the performance of full-duplex relaying (FDR) and half-duplex relaying (HDR) dual-hop networks under SPCs in terms of the block error rate (BLER). The results of [12] have revealed that the FDR scheme achieves better performance than that of HDR with less stringent BLER requirements and low transmit power constraints. In [13], a dual-hop hybrid automatic repeat request IoT network was investigated with SPCs, where the users utilized either selection combining or maximum ratio combining (MRC) to detect the signals. Analyzing results in [13] have confirmed that the MRC scheme achieves superior performance compared to the selection combining scheme with big-enough transmit power and a long-enough blocklength. Subsequently, in [14], Makki *et al.* considered SPCs in multi-relay networks, where relays applied either amplitude-and-forward (AF) or decode-and-forward (DF) schemes to transmit and process the information. It is shown that the end-to-end (e2e) throughput of the DF scheme achieves better performance than that of the AF scheme when increasing the number of hops in a wider range of decoding delays.

A joint optimization investigation of power allocation (PA) and relay location (RL) configurations for multihop MIMO relay networks with SPCs was provided in [15]. Meanwhile, the work [16] considered the partial relay-selection (PRS) technique, in which the best relay was selected to forward the signal to the destination. The results in [16] have yielded a tradeoff that increasing SNR and blocklength improve system performance while increasing latency as the longer packets.

In this paper, to leverage the above aforementioned benefits of the relay networks, we first study a DF multi-relay scheme

Manuscript received December 4, 2021; revised March 21, 2022; approved for publication by Young-Chai Ko, Division 2 Editor, May 22, 2022.

N. T. Y. Linh is with the Faculty of Electrical and Electronics Engineering, Ho Chi Minh City University of Technology and Education, Ho Chi Minh City 710372, and the Department of Fundamental Science, Posts and Telecommunications Institute of Technology, Ho Chi Minh City 710372, Vietnam, email: linhnty.ncs@hcmute.edu.vn.

N. H. Tu is with the Department of Smart Energy Systems, Seoul National University of Science and Technology, Seoul 01811, South Korea, and the Department of Computer Engineering, Ho Chi Minh City University of Transport, Ho Chi Minh City 710372, Vietnam, email: tu.ngo@ut.edu.vn.

P. N. Son is with the Faculty of Electrical and Electronics Engineering, Ho Chi Minh City University of Technology and Education, Ho Chi Minh City 710372, Vietnam, email: sonpndtyt@hcmute.edu.vn.

V. N. Q. Bao is with the Wireless Communications Department, Posts and Telecommunications Institute of Technology, Ho Chi Minh City 710372, Vietnam, email: baovngq@ptithcm.edu.vn.

V. N. Q. Bao is the corresponding author.

Creative Commons Attribution-NonCommercial (CC BY-NC).

This is an Open Access article distributed under the terms of Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided that the original work is properly cited.

in a dual-hop network with SPCs to support not only ultra-reliability but also low-latency, where (i) the transmit antenna selection (TAS) scheme is conducted for the signal processing of multiple transmit antennas of the source, (ii) the PRS technique is utilized to determine the best relay having the highest SNR among multiple relays, and (iii) the destination uses the MRC technique for multiple installed antennas to achieve the highest diversity gain. Our main contributions are summarized as follows:

- We derive the approximated and asymptotic closed-form expressions of the e2e BLERs for both the selective DF (SDF) and fixed DF (FDF) schemes in the finite-blocklength regime and quasi-static Rayleigh fading channels. The result indicates that the BLERs of the two schemes are identical in the average and high-SNR regions but distinguished in the low-SNR regime.
- We also investigate the performance in terms of e2e latency and system throughput to provide a comprehensive overview of not only ultra-reliability but also low-latency standpoints.
- We propose two asymptotic approaches for the e2e BLER, in which the second asymptotic approach is a way to validate the correctness of the first approach. This reveals that both of the asymptotic approaches for the e2e BLER perfectly match with each other.
- We analyze two important practical optimization problems, including PA and RL, which are obtained in the closed-form expressions for the designed configurations.

The remaining of this paper is organized as follows. In Section II, we describe the proposed system model and derive the preliminary essential cumulative distribution function (CDF) forms. The BLER analysis of the proposed system model with both approximated and asymptotic expressions is presented in Section III. Subsequently, the optimization problems of PA and RL are analyzed in Section IV. Numerical and simulation results are discussed in Section V. Eventually, the conclusion is provided in Section VI.

II. SYSTEM MODEL

As illustrated in Fig. 1, we consider a dual-hop network consisting of a based station performed as a source ($\mathcal{S}$) equipped with antennas $\mathcal{S}_t$ ($t = 1, 2, \dots, T$), N single-antenna relays $\mathcal{R}_n$ ($n = 1, 2, \dots, N$), and a destination ($\mathcal{D}$) installed with antennas $\mathcal{D}_m$ ($m = 1, 2, \dots, M$)¹. We assume that there is no direct link between the source and destination. The system operates in a time-division multiple-access method with two consecutive time slots via the help of the relays.

In the first time slot, the source transmits its signals to all relays, where the TAS and PRS techniques are simultaneously utilized. Based on the TAS principle, the system selects only one optimal transmit antenna, which maximizes the received SNR, out of T antennas of the source to perform the transmission. We note that the TAS scheme on the transmit side can achieve a significant reduction in hardware cost and power

¹The value of $t = 1, 2, \dots, T$, $n = 1, 2, \dots, N$, and $m = 1, 2, \dots, M$ will be used throughout this paper if we do not specifically mention.




Fig. 1. A dual-hop TAS/PRS/MRC relay system with SPCs.

consumption because only a single radio-frequency chain is used. Subsequently, the PRS scheme is used with the principle that only the relay having the highest SNR is selected as a forwarder for the next hop. Denoting $\mathcal{R}_b$ as the selected relay after utilizing the TAS and PRS schemes [17], [18], we have

$$b = \arg \max_{\substack{t=1, \dots, T \\ n=1, \dots, N}} \gamma_{\mathcal{S}\mathcal{R}_{t,n}}, \quad (1)$$

where $\gamma_{\mathcal{S}\mathcal{R}_b}$ denotes the output SNR in the first hop and $\gamma_{\mathcal{S}\mathcal{R}_{t,n}}$ is the SNR of the link from $\mathcal{S}_t \rightarrow \mathcal{R}_n$. Here, $\gamma_{\mathcal{S}\mathcal{R}_{t,n}}$ follows the exponential distribution with the average SNR being calculated as

$$\bar{\gamma}_{\mathcal{S}\mathcal{R}_{t,n}} = \frac{P_S}{\sigma^2} \mathbb{E} \{ |h_{t,n}|^2 \} = \frac{P_S}{\sigma^2} \Omega_{\mathcal{S}\mathcal{R}_{t,n}}, \quad (2)$$

where P_S is the transmit power of $\mathcal{S}$, $h_{t,n}$ and $\Omega_{\mathcal{S}\mathcal{R}_{t,n}}$ are the channel coefficient and average channel gain of the link from $\mathcal{S}_t \rightarrow \mathcal{R}_n$, respectively, and σ^2 denotes the additive white Gaussian noise variance. The CDF of $\gamma_{\mathcal{S}\mathcal{R}_b}$ is given as

$$F_{\gamma_{\mathcal{S}\mathcal{R}_b}}(\gamma) = \prod_{t=1}^T \prod_{n=1}^N \Pr(\gamma_{\mathcal{S}\mathcal{R}_{t,n}} \leq \gamma) = \prod_{t=1}^T \prod_{n=1}^N F_{\gamma_{\mathcal{S}\mathcal{R}_{t,n}}}(\gamma). \quad (3)$$

We assume that the channel coefficients in each hop are quasi-static block-fading channels [8], where channel fading coefficients remain the constant value during each transmission block and change independently in the another transmission. The independent and identically distributed (i.i.d.) channels are also assumed with the links of $\mathcal{S}_t \rightarrow \mathcal{R}_n$ and $\mathcal{R}_b \rightarrow \mathcal{D}_m$. In such a scenario, the average SNRs for all of the branches $\bar{\gamma}_{\mathcal{S}\mathcal{R}_{t,n}}$ are the same, i.e., $\bar{\gamma}_{\mathcal{S}\mathcal{R}_{t,n}} = \bar{\gamma}_{\mathcal{S}\mathcal{R}}$. As a result, the CDF of the output SNR in the first hop $\gamma_{\mathcal{S}\mathcal{R}_b}$ is given by [18, Eq. (3)]

$$\begin{aligned} F_{\gamma_{\mathcal{S}\mathcal{R}_b}}(\gamma) &= \left[1 - \exp\left(-\frac{\gamma}{\bar{\gamma}_{\mathcal{S}\mathcal{R}}}\right) \right]^{NT} \\ &= \sum_{n=1}^{NT} (-1)^{n-1} \binom{NT}{n} \left[1 - \exp\left(-\frac{n\gamma}{\bar{\gamma}_{\mathcal{S}\mathcal{R}}}\right) \right]. \end{aligned} \quad (4)$$

In the second time slot, the best relay node uses DF technique to decode successfully the received signal and transfer this signal to the destination $\mathcal{D}$. At the destination $\mathcal{D}$, the spatial diversity MRC protocol is investigated, i.e., it combines all channels $\mathcal{R}_b \rightarrow \mathcal{D}_m$ at the destination. Therefore, the output

SNR at the destination will increase linearly with the number of diversity branches. As a result, the SNR at the output of the MRC selector is determined by

$$\gamma_{\mathcal{R}_b\mathcal{D}} = \sum_{m=1}^M \gamma_{\mathcal{R}_b\mathcal{D}_m}, \quad (5)$$

where $\gamma_{\mathcal{R}_b\mathcal{D}_m}$ is the received SNR at the antenna $\mathcal{D}_m$. Under i.i.d. Rayleigh fading assumption for the link of $\mathcal{R}_b \rightarrow \mathcal{D}_m$, we also have $\bar{\gamma}_{\mathcal{R}_b\mathcal{D}_m} = \bar{\gamma}_{\mathcal{R}_b\mathcal{D}} = P_{\mathcal{R}_b}\Omega_{\mathcal{R}_b\mathcal{D}}/\sigma^2$, where $P_{\mathcal{R}_b}$ is the transmit power at $\mathcal{R}_b$ and $\Omega_{\mathcal{R}_b\mathcal{D}}$ is the average channel gain of the link from $\mathcal{R}_b \rightarrow \mathcal{D}$. We note that $|g_m|^2$ follows the exponential distribution so that $\gamma_{\mathcal{R}_b\mathcal{D}_m}$ follows the chi-squared distribution with a mean of $M\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}$ and variance $2M\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}$ [19]. Accordingly, the CDF of $\gamma_{\mathcal{R}_b\mathcal{D}}$ is given by

$$F_{\gamma_{\mathcal{R}_b\mathcal{D}}}(\gamma) = 1 - \exp\left(-\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}}\right) \sum_{m=1}^M \frac{\left(\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}}\right)^{m-1}}{(m-1)!}. \quad (6)$$

III. PERFORMANCE ANALYSIS

In this section, we derive the approximated closed-form expression for the e2e BLER under the finite-blocklength regime. The asymptotic analysis are further studied to gain more insights into the performance behavior in the high-SNR regime. Furthermore, the performance in terms of e2e latency and throughput is also considered.

A. Average BLER

We assume that each transmission blocklength is k channel uses (CUs). When $\mathcal{S}$ transmits β information bits to $\mathcal{D}$ over k during each packet transmission, the coding rate of the proposed system is $r = 2\beta/k$. For SPCs, the minimum blocklength should be larger than 100 CUs [20], the average BLER can be tightly approximated as [15, Eq. (9)]

$$\bar{\epsilon}_{\mathcal{X}} \approx \mathbb{E} \left\{ Q \left(\frac{C(\gamma_{\mathcal{X}}) - r}{\sqrt{V(\gamma_{\mathcal{X}})/k}} \right) \right\}, \quad (7)$$

where $\mathcal{X} \in \{\mathcal{SR}_b, \mathcal{R}_b\mathcal{D}\}$, $C(\gamma_{\mathcal{X}}) = \log_2(1 + \gamma_{\mathcal{X}})$ is the Shannon channel capacity, $V(\gamma_{\mathcal{X}}) = \left(1 - 1/(1 + \gamma_{\mathcal{X}})^2\right)(\log_2 e)^2$ is the channel dispersion measuring the random variation of a channel compared to a defined channel for the same capacity, $\mathbb{E}\{\cdot\}$ is the expectation operator, and $Q(\cdot)$ is the Gaussian Q-function [21]. From (7), we observe that the form of Gaussian Q-function is too complicated, which yields that it is intractable to solve (7) directly. We now invoke the approximated linear form of $Q\left((C(\gamma_{\mathcal{X}}) - r)/\sqrt{V(\gamma_{\mathcal{X}})/k}\right) \approx \Phi(\gamma_{\mathcal{X}})$ [20, Eq. (14)] with

$$\Phi(\gamma_{\mathcal{X}}) = \begin{cases} 1, & \gamma_{\mathcal{X}} \leq \rho_L, \\ 0.5 - v\sqrt{k}(\gamma_{\mathcal{X}} - \theta), & \rho_L < \gamma_{\mathcal{X}} < \rho_H, \\ 0, & \gamma_{\mathcal{X}} \geq \rho_H, \end{cases} \quad (8)$$

where $v = 1/\sqrt{2\pi(2^{2r} - 1)}$, $\theta \triangleq 2^r - 1$, $\rho_H = \theta + 1/(2v\sqrt{k})$, and $\rho_L = \theta - 1/(2v\sqrt{k})$.

By inserting (8) into (7), the average BLER for the scheme $\mathcal{S}$ can be tightly approximated as

$$\bar{\epsilon}_{\mathcal{X}} \approx \int_0^\infty \Phi(\gamma) f_{\gamma_{\mathcal{X}}}(\gamma) d\gamma, \quad (9)$$

where $f_{\gamma_{\mathcal{X}}}(\gamma)$ denotes the probability density function of $\gamma_{\mathcal{X}}$. Subsequently, (9) is calculated by utilizing the partial integration method, which yields

$$\begin{aligned} \bar{\epsilon}_{\mathcal{X}} &\approx \int_0^\infty \Phi(\gamma) dF_{\gamma_{\mathcal{X}}}(\gamma) \\ &= \left(\Phi(\gamma) F_{\gamma_{\mathcal{X}}}(\gamma) \right) \Big|_{\gamma=0}^{\gamma=\infty} - \int_0^\infty F_{\gamma_{\mathcal{X}}}(\gamma) d\Phi(\gamma) \\ &= v\sqrt{k} \int_{\rho_L}^{\rho_H} F_{\gamma_{\mathcal{X}}}(\gamma) d\gamma. \end{aligned} \quad (10)$$

By substituting (4) and (6) into (10), the average BLERs at the first and second hop are obtained, respectively, as

$$\begin{aligned} \bar{\epsilon}_{\mathcal{SR}_b} &\approx 1 + v\sqrt{k} \sum_{n=1}^{NT} (-1)^{n-1} \binom{NT}{n} \frac{\bar{\gamma}_{\mathcal{SR}}}{n} \\ &\quad \cdot \left\{ \exp\left(-\frac{n\rho_H}{\bar{\gamma}_{\mathcal{SR}}}\right) - \exp\left(-\frac{n\rho_L}{\bar{\gamma}_{\mathcal{SR}}}\right) \right\}, \end{aligned} \quad (11)$$

$$\begin{aligned} \bar{\epsilon}_{\mathcal{R}_b\mathcal{D}} &\approx 1 - v\sqrt{k} \sum_{m=1}^M \frac{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}}{(m-1)!} \\ &\quad \cdot \left\{ \Upsilon\left(m, \frac{\rho_H}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}}\right) - \Upsilon\left(m, \frac{\rho_L}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}}\right) \right\}, \end{aligned} \quad (12)$$

where $\Upsilon(\cdot, \cdot)$ is the lower incomplete Gamma function with $\Upsilon(m, x) = \int_0^x t^{m-1} \exp(-t) dt$ [22].

Proposition 1. *Since the SDF scheme is considered at relays [23], where the relay node supports only when it is able to decode successfully the source information. As a result, the e2e BLER can be calculated as*

$$\bar{\epsilon}_{\text{e2e}}^{\text{SDF}} = \bar{\epsilon}_{\mathcal{SR}_b} + (1 - \bar{\epsilon}_{\mathcal{SR}_b}) \bar{\epsilon}_{\mathcal{R}_b\mathcal{D}}. \quad (13)$$

Otherwise, since FDF is utilized at relays [24], where the selected relay always decodes and forwards the source information without regarding the ability of prosperous decoding. In such a scenario, the e2e BLER is given by

$$\bar{\epsilon}_{\text{e2e}}^{\text{FDF}} = \bar{\epsilon}_{\mathcal{SR}_b} (1 - \bar{\epsilon}_{\mathcal{R}_b\mathcal{D}}) + (1 - \bar{\epsilon}_{\mathcal{SR}_b}) \bar{\epsilon}_{\mathcal{R}_b\mathcal{D}}. \quad (14)$$

B. Asymptotic BLER

In this subsection, to observe the qualitative conclusions on the system performance, we present the asymptotic forms of the e2e BLERs in the high-SNR regime, where the first asymptotic approach is utilized to highlight the illustration of asymptotic characteristics and the second approach is to validate the first one.

1) *The first approach:* In the high-SNR regime, by applying the equivalent infinitesimal series of $1 - \exp(-x) \stackrel{x \rightarrow 0}{\sim} x$ to (10), the asymptotic BLER of the first hop is calculated as

$$\tilde{\varepsilon}_{\mathcal{SR}_b}^{(1)} \approx v\sqrt{k} \int_{\rho_L}^{\rho_H} \left(\frac{\gamma}{\bar{\gamma}_{\mathcal{SR}}} \right)^{NT} d\gamma = \frac{v\sqrt{k} (\rho_H^{NT+1} - \rho_L^{NT+1})}{(NT+1) \bar{\gamma}_{\mathcal{SR}}^{NT}}. \quad (15)$$

The asymptotic BLER of the second hop is solved by invoking the helps of [22, Eq.(8.352.6)] and [22, Eq.(8.354.1)] for (10), as given respectively by

$$\Upsilon \left(M, \frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right) = (M-1)! \left[1 - \exp \left(-\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right) \sum_{m=1}^M \frac{1}{(m-1)!} \left(\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right)^{m-1} \right], \quad (16)$$

$$\Upsilon \left(M, \frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right) = \left(\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right)^M \sum_{n=0}^{\infty} \frac{(-1)^n}{n! (M+n)} \left(\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right)^n \stackrel{\gamma/\bar{\gamma}_{\mathcal{R}_b\mathcal{D}} \rightarrow 0}{\approx} \frac{1}{M} \left(\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right)^M. \quad (17)$$

As a result, we get

$$\tilde{\varepsilon}_{\mathcal{R}_b\mathcal{D}}^{(1)} \approx v\sqrt{k} \int_{\rho_L}^{\rho_H} \frac{1}{M!} \left(\frac{\gamma}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right)^M d\gamma = \frac{v\sqrt{k} (\rho_H^{M+1} - \rho_L^{M+1})}{M! (M+1) \bar{\gamma}_{\mathcal{R}_b\mathcal{D}}^M}. \quad (18)$$

We note the value of BLER will be very small in the high-SNR range, i.e., $\tilde{\varepsilon}_{\mathcal{SR}_b} \ll 1$ and $\tilde{\varepsilon}_{\mathcal{R}_b\mathcal{D}} \ll 1$. Accordingly, **Proposition 1** can be simplified, yielding the e2e asymptotic BLER for the first approach as

$$\tilde{\varepsilon}_{e2e}^{(1)} \approx \tilde{\varepsilon}_{\mathcal{SR}_b}^{(1)} + \tilde{\varepsilon}_{\mathcal{R}_b\mathcal{D}}^{(1)}. \quad (19)$$

2) *Riemann integral approximation:* By revisiting (10), we find that the value of $\rho_H - \rho_L = \sqrt{2\pi(2^{2r} - 1)/k}$ is small since r is small as $k \geq 100$ [20]. In such a scenario, the first-order Riemann integral approximation $\int_a^b f(x)dx = (b-a)f\left(\frac{a+b}{2}\right)$ is valid for (10). As a result, the asymptotic BLERs for the first hop and second hop are given, respectively, by

$$\tilde{\varepsilon}_{\mathcal{SR}_b}^{(2)} \approx F_{\gamma_{\mathcal{SR}_b}}(\theta) \stackrel{\text{high-SNR}}{\approx} \left(\frac{\theta}{\bar{\gamma}_{\mathcal{SR}}} \right)^{NT}, \quad (20)$$

$$\tilde{\varepsilon}_{\mathcal{R}_b\mathcal{D}}^{(2)} \approx F_{\gamma_{\mathcal{R}_b\mathcal{D}}}(\theta) \stackrel{\text{high-SNR}}{\approx} \frac{1}{M!} \left(\frac{\theta}{\bar{\gamma}_{\mathcal{R}_b\mathcal{D}}} \right)^M. \quad (21)$$

Similar to (19), the e2e asymptotic BLER in for the second approach is obtained as

$$\tilde{\varepsilon}_{e2e}^{(2)} \approx \tilde{\varepsilon}_{\mathcal{SR}_b}^{(2)} + \tilde{\varepsilon}_{\mathcal{R}_b\mathcal{D}}^{(2)}. \quad (22)$$

Remark 1. We observe that the average BLER of each hop in (10) is only dependent on the CDF function of $\gamma_{\mathcal{X}}$. When

$F_{\gamma_{\mathcal{X}}}(\gamma)$ becomes too complicated, the first asymptotic approach can be intractable to obtain the closed-form expression for the average BLER. Instead of using the first asymptotic method, we can utilize the Riemann integral approximation to simplify the calculation. In this paper, we do not only utilize the second context to reduce the calculating complexity but also validate the correctness of the first approach.

Proposition 2 (Diversity order). By denoting the average total transmit SNR as $\bar{\gamma} = P_0/\sigma^2$, the transmit power constraints with $P_S/\sigma^2 = \phi\bar{\gamma}$ and $P_{\mathcal{R}_b}/\sigma^2 = (1-\phi)\bar{\gamma}$ are satisfied, where $\phi \in (0, 1)$ denotes the PA coefficient for the source $\mathcal{S}$. The diversity order of the proposed system is determined by [25]

$$\begin{aligned} \Theta &= - \lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \left(\tilde{\varepsilon}_{e2e}^{(1)} \right)}{\log(\bar{\gamma})} \\ &= - \lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \left(\tilde{\varepsilon}_{e2e}^{(2)} \right)}{\log(\bar{\gamma})} \\ &= \min(NT, M). \end{aligned} \quad (23)$$

Proof. From (19) and (22), we express the diversity order of the considered system, respectively, in the forms of [25]

$$\begin{aligned} \Theta &= - \lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \left(\tilde{\varepsilon}_{e2e}^{(1)} \right)}{\log(\bar{\gamma})} \\ &= - \lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \left(\frac{\varsigma_1}{\bar{\gamma}^{NT}} + \frac{\varsigma_2}{\bar{\gamma}^M} \right)}{\log(\bar{\gamma})} = \min(NT, M), \end{aligned} \quad (24)$$

$$\begin{aligned} \Theta &= - \lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \left(\tilde{\varepsilon}_{e2e}^{(2)} \right)}{\log(\bar{\gamma})} \\ &= - \lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \left(\frac{\varsigma_3}{\bar{\gamma}^{NT}} + \frac{\varsigma_4}{\bar{\gamma}^M} \right)}{\log(\bar{\gamma})} = \min(NT, M), \end{aligned} \quad (25)$$

where

$$\varsigma_1 = \frac{v\sqrt{k} (\rho_H^{NT+1} - \rho_L^{NT+1})}{(NT+1) (\Omega_{\mathcal{SR}} \phi)^{NT}}, \quad (26)$$

$$\varsigma_2 = \frac{v\sqrt{k} (\rho_H^{M+1} - \rho_L^{M+1})}{M! (M+1) (\Omega_{\mathcal{R}_b\mathcal{D}} (1-\phi))^M}, \quad (27)$$

$$\varsigma_3 = \frac{\theta^{NT}}{(\Omega_{\mathcal{SR}} \phi)^{NT}}, \quad (28)$$

$$\varsigma_4 = \frac{\theta^M}{M! (\Omega_{\mathcal{R}_b\mathcal{D}} (1-\phi))^M}. \quad (29)$$

The proof is concluded. $\square$

C. e2e Latency and Throughput

The e2e latency is characterized by the average delay during transmission and decoding. Let $\mathcal{L}(k)$ denote the delay for decoding a packet with the blocklength k . Based on [14, Eq. (6)], the e2e packet transmission latency (measured in the number of CUs) is given by

$$\begin{aligned} \tau &= \underbrace{(k + \mathcal{L}(k)) (1 - \bar{\varepsilon}_{S\mathcal{R}_b})}_{\text{First hop delay}} + \underbrace{k + \mathcal{L}(k)}_{\text{Second hop delay}} \\ &= (k + \mathcal{L}(k)) (2 - \bar{\varepsilon}_{S\mathcal{R}_b}), \end{aligned} \quad (30)$$

where $\mathcal{L}(k) = \alpha k$ with α being a constant that represents the decoding delay factor [26, Lemma 6]. We note that in (30), the total latency is taken into account only when the best relay successfully decodes the signal and then the message arrives at the destination, regardless of whether this message is successfully decoded at the destination or not, which is precise to the analysis in [14, Eq. (6)].

Besides that, the e2e throughput is defined as the ratio of the number of information bits successfully received at the destination and the e2e packet transmission latency, which is measured in bits per CU (BPCU). As a result, the e2e throughput for the considered system is expressed as

$$\delta = \frac{\beta (1 - \bar{\varepsilon}_{e2e})}{\tau}. \quad (31)$$

IV. OPTIMIZATION ISSUES

This section investigates the optimization problems for PA and RL to minimize the e2e BLER under the system configuration and uRLLC constraints.

A. PA Optimization

In this subsection, we will answer the important question of the relay system under the fixed coordinations of the network nodes, how is transmit power distributed to the source and relay nodes for the best system performance? The optimal PA optimization problem is given by

$$\min_{\mathbf{P}} \bar{\varepsilon}_{e2e}(\mathbf{P}) \text{ s.t. } P_S + P_{\mathcal{R}_b} \leq P_0, \quad (32)$$

where $\mathbf{P}$ is a set of transmit power variables, i.e., $\mathbf{P} = (P_S, P_{\mathcal{R}_b})$, and P_0 denotes the total transmit power budget of the system.

It is noted that the optimization problem (32) is non-convex because the objective function $\bar{\varepsilon}_{e2e}(\mathbf{P})$ is a non-convex function. Therefore, we attempt to transform (32) into a convex optimization problem. For uRLLCs, the e2e BLER must be lower than 10^{-5} [5], which requires a high SNR. As a result, we can invoke (22)² for the objective function in (32). Specifically, the problem (32) can be approximated as

$$\min_{P_S, P_{\mathcal{R}_b}} \hat{\varepsilon}_{S\mathcal{R}_b}^{(2)} + \hat{\varepsilon}_{\mathcal{R}_b\mathcal{D}}^{(2)} \text{ s.t. } P_S + P_{\mathcal{R}_b} \leq P_0. \quad (33)$$

²We note that since the results of the first and second asymptotic approaches are identical, the second strategy, however, provides lower calculating complexity. Therefore, we consider (22) as the objective function for simplification.

By inserting (20) and (21) into (33), the optimization problem (33) becomes

$$\begin{aligned} \min_{P_S, P_{\mathcal{R}_b}} & \left(\frac{\theta \sigma^2 d_1^\eta}{P_S} \right)^{NT} + \frac{1}{M!} \left(\frac{\theta \sigma^2 d_2^\eta}{P_{\mathcal{R}_b}} \right)^M \\ \text{s.t. } & P_S + P_{\mathcal{R}_b} \leq P_0, \end{aligned} \quad (34)$$

where d_1 is the distance between the source and multiple relays and d_2 is the distance between multiple relays and the destination. We assume the simplified pathloss model [19] with the average channel power gains $\Omega_{S\mathcal{R}_b} = d_1^{-\eta}$ and $\Omega_{\mathcal{R}_b\mathcal{D}} = d_2^{-\eta}$, where η denotes the pathloss exponent.

Proposition 3. *The optimization problem (34) is convex. Therefore, the Lagrangian multiplier method is beneficial to find a single global optimal solution $\mathbf{P}^*$.*

Proof. By considering the Hessian matrix [27, Theorem. (A.2)]

$$\mathbf{H}(\mathbf{P}) = \begin{bmatrix} \frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_S^2} & \frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_S \partial P_{\mathcal{R}_b}} \\ \frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_{\mathcal{R}_b} \partial P_S} & \frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_{\mathcal{R}_b}^2} \end{bmatrix}, \quad (35)$$

where

$$\frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_{\mathcal{R}_b} \partial P_S} = \frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_S \partial P_{\mathcal{R}_b}} = 0, \quad (36)$$

$$\frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_S^2} = \frac{NT(NT+1)(\theta \sigma^2 d_1^\eta)^{NT}}{P_S^{NT+2}} > 0, \quad (37)$$

$$\frac{\partial^2 \hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})}{\partial P_{\mathcal{R}_b}^2} = \frac{M(M+1)(\theta \sigma^2 d_2^\eta)^M}{M! P_{\mathcal{R}_b}^{M+2}} > 0. \quad (38)$$

Because all diagonal elements of $\mathbf{H}(\mathbf{P})$ are positive, $\mathbf{H}(\mathbf{P})$ is positive definite. As a result, $\hat{\varepsilon}_{e2e}^{(2)}(\mathbf{P})$ in (34) is a strictly convex function. Since the constraint is affine, the optimization problem (34) is convex, which completes the proof. $\square$

Based on **Proposition 3**, we use the Lagrangian multiplier method to determine $\mathbf{P}^*$, where the Lagrange function of (34) is given by

$$\Delta_1(\mathbf{P}, \psi_1) = \frac{(\theta \sigma^2 d_1^\eta)^{NT}}{P_S^{NT}} + \frac{(\theta \sigma^2 d_2^\eta)^M}{M! P_{\mathcal{R}_b}^M} - \psi_1 (P_S + P_{\mathcal{R}_b} - P_0), \quad (39)$$

where ψ_1 is a Lagrange multiplier constant. By considering the partial derivatives of $\Delta_1(\mathbf{P}, \psi_1)$ with respect to P_S , $P_{\mathcal{R}_b}$, and P_0 equal to zero, we get

$$\begin{cases} \frac{\partial \Delta_1(\mathbf{P}, \psi_1)}{\partial P_S} = -\frac{(\theta \sigma^2 d_1^\eta)^{NT} NT}{P_S^{NT+1}} - \psi_1 = 0, & (\mathcal{F}_1), \\ \frac{\partial \Delta_1(\mathbf{P}, \psi_1)}{\partial P_{\mathcal{R}_b}} = -\frac{(\theta \sigma^2 d_2^\eta)^M M}{P_{\mathcal{R}_b}^{M+1} M!} - \psi_1 = 0, & (\mathcal{F}_2), \\ \frac{\partial \Delta_1(\mathbf{P}, \psi_1)}{\partial \psi_1} = P_S + P_{\mathcal{R}_b} - P_0 = 0, & (\mathcal{F}_3). \end{cases} \quad (40)$$

By considering $(\mathcal{F}_1) - (\mathcal{F}_2)$, we obtain

$$P_{\mathcal{R}_b} = \left(\frac{(\theta \sigma^2 d_2^\eta)^M M}{(\theta \sigma^2 d_1^\eta)^{NT} M! NT} \right)^{\frac{1}{M+1}} P_S^{\frac{NT+1}{M+1}}. \quad (41)$$

By substituting (41) into $(\mathcal{F}_3)$, we get

$$\underbrace{P_S + \mathcal{Z}_1 P_S^{\frac{NT+1}{M+1}}}_{\triangleq g(P_S)} = P_0, \quad (42)$$

where $\mathcal{Z}_1 = \left(\frac{(\theta\sigma^2 d_2^\eta)^M M}{(\theta\sigma^2 d_1^\eta)^{NT} M! NT} \right)^{\frac{1}{M+1}}$. We note that, when P_S , $\mathcal{Z}_1 > 0$, and $M, N, T \in \mathbb{N}^*$, $g(P_S)$ is an monotonically increasing function because of $\frac{\partial g(P_S)}{\partial P_S} = 1 + \mathcal{Z}_1 \frac{NT+1}{M+1} P_S^{\frac{NT-M}{M+1}} > 0$. Furthermore, the right hand side of (42) is a constant function. When $g(0) = 0$, $g(P_S) > 0$, and $P_0 > 0$, (42) only has a unique solution. To solve (42), we consider the following proposition.

Proposition 4 (Newton–Raphson iterative root-finding algorithm). *We consider $f(x)$, from a well-chosen value x_0 , the iterations for a unique root of $f(x)$ can be determined as*

$$x_{n+1} = x_n - \frac{f(x_n)}{\partial f(x_n)/\partial x_n}. \quad (43)$$

Eventually, x_{n+1} converges to a unique root.

Proof. Based on the definition of the derivative, we have $\frac{\partial f(\hat{x})}{\partial \hat{x}} = \lim_{x \rightarrow \hat{x}} \frac{f(x) - f(\hat{x})}{x - \hat{x}}$. This also means

$$\frac{\partial f(\hat{x})}{\partial \hat{x}} \rightarrow \frac{f(x) - f(\hat{x})}{x - \hat{x}}, \quad (44)$$

where the notation $\rightarrow$ represents the convergence. Assuming that $\hat{x}$ is a solution, we have $f(\hat{x}) = 0$. From (44), we get $\frac{\partial f(\hat{x})}{\partial \hat{x}} \rightarrow \frac{f(x)}{x - \hat{x}}$, which yields

$$x - \frac{f(x)}{\partial f(\hat{x})/\partial \hat{x}} \rightarrow \hat{x}, \quad (45)$$

where $\hat{x}$ is a converged unique solution. The proof is concluded. $\square$

Remark 2. We note that the non-linear function (42) with its constraints has sufficient conditions to satisfy the guaranteed convergence requirement for both the Newton–Raphson and other search methods (e.g., Bisection, Secant, Bairstow), i.e., a single variable function with a unique real root and an easily determinable derivative. In this context, since a fair comparison between the Newton–Raphson and other search methods is guaranteed, the Newton–Raphson method offers the quickest convergence rate [28]. Although the Bisection search method is the simplest method to understand, it has the linear rate of convergence, which is the search method with the lowest convergence rate. Meanwhile, the Secant and Bairstow search methods have aureal number and quadratic convergence rates, respectively, which are higher ones than that of the Bisection search method but lower than that of the Newton–Raphson method. As a result, the used Newton–Raphson search method is the most efficient selection in our scope.

By utilizing **Proposition 4**, **Algorithm 1** is utilized to find the solution P_S^* for (42). Based on the optimal solution P_S^*

Algorithm 1 Iterative root-finding for (42)

Input: $\theta, \sigma^2, d_1, d_2, \eta, M, N, T, P_0$

Output: P_S^*

- 1: Initialize the maximum number of iteration $N_{\max} = 1000$ and $P_{S,0} = 1$
 - 2: Compute $\mathcal{Z}_1 = \left(\frac{(\theta\sigma^2 d_2^\eta)^M M}{(\theta\sigma^2 d_1^\eta)^{NT} M! NT} \right)^{\frac{1}{M+1}}$
 - 3: **for** $0 \leq n \leq N_{\max}$ **do**
 - 4: $f(P_{S,n}) = P_{S,n} + \mathcal{Z}_1 P_{S,n}^{\frac{NT+1}{M+1}} - P_0$
 - 5: $\frac{\partial f(P_{S,n})}{\partial P_{S,n}} = 1 + \mathcal{Z}_1 \frac{NT+1}{M+1} P_{S,n}^{\frac{NT-M}{M+1}}$
 - 6: $P_{S,n+1} = P_{S,n} - \frac{f(P_{S,n})}{\partial f(P_{S,n})/\partial P_{S,n}}$
 - 7: **end for**
 - 8: Solution $P_S^* = P_{S,N_{\max}+1}$
-

attained from **Algorithm 1** and $(\mathcal{F}_3)$, the optimal $P_{\mathcal{R}_b}^*$ is given by

$$P_{\mathcal{R}_b}^* = P_0 - P_S^*. \quad (46)$$

Remark 3. We note that, in a special case with $NT = M$, (42) can be easily solved and yields a unique solution as

$$\begin{cases} P_S^* = \phi P_0, \\ P_{\mathcal{R}_b}^* = (1 - \phi) P_0, \end{cases} \quad (47)$$

where $\phi = \left(1 + (1/M!)^{1/(M+1)} (d_2/d_1)^{(\eta M)/(M+1)} \right)^{-1}$.

B. RL Optimization

In this subsection, the optimal RL configuration is designed to minimize the e2e BLER with the constraint of the normalized transmission distance and the given PA configuration. Since the original RL optimization is non-convex, we formulate the optimal RL problem as a convex optimization by utilizing the same hypotheses as those in the PA optimization problem. Specifically,

$$\min_{\mathbf{d}} \tilde{\varepsilon}_{e2e}^{(2)}(\mathbf{d}) = \min_{d_1, d_2} \tilde{\varepsilon}_{S\mathcal{R}_b}^{(2)} + \tilde{\varepsilon}_{\mathcal{R}_b\mathcal{D}}^{(2)} \text{ s.t. } d_1 + d_2 = D, \quad (48)$$

where $\mathbf{d} = (d_1, d_2)$ and D represents the normalized transmit distance. By substituting (20) and (21) into (48), we get

$$\min_{d_1, d_2} \left(\frac{\theta\sigma^2 d_1^\eta}{P_S} \right)^{NT} + \frac{1}{M!} \left(\frac{\theta\sigma^2 d_2^\eta}{P_{\mathcal{R}_b}} \right)^M \text{ s.t. } d_1 + d_2 = D. \quad (49)$$

By following the same footsteps as **Proposition 3**, it is the fact that (49) is a convex optimization problem. Therefore, the Lagrangian multiplier method is beneficial to find the global optimal solution $\mathbf{d}^*$. We define the Lagrangian cost function for (49) as

$$\Delta_2(\mathbf{d}, \psi_2) = \left(\frac{\theta\sigma^2 d_1^\eta}{P_S} \right)^{NT} + \frac{1}{M!} \left(\frac{\theta\sigma^2 d_2^\eta}{P_{\mathcal{R}_b}} \right)^M - \psi_2 (d_1 + d_2 - D), \quad (50)$$

Algorithm 2 Iterative root-finding for (53)

Input: $\theta, \sigma^2, P_S, P_{\mathcal{R}}, \eta, M, N, T, D$
Output: d_1^*

- 1: Initialize the maximum number of iteration $N_{\max} = 1000$ and $d_{1,0} = 1$
 - 2: Compute $\mathcal{Z}_2 = \left(\frac{(\theta\sigma^2)^{NT} N T P_{\mathcal{R}_b}^M M!}{(\theta\sigma^2)^M M P_S^{NT}} \right)^{\frac{1}{M\eta-1}}$
 - 3: **for** $0 \leq n \leq N_{\max}$ **do**
 - 4: $f(d_{1,n}) = d_{1,n} + \mathcal{Z}_2 d_{1,n}^{\frac{NT\eta-1}{M\eta-1}} - D$
 - 5: $\frac{\partial f(d_{1,n})}{\partial d_{1,n}} = 1 + \frac{NT\eta-1}{M\eta-1} \mathcal{Z}_2 d_{1,n}^{\frac{\eta(NT-M)}{M\eta-1}}$
 - 6: $d_{1,n+1} = d_{1,n} - \frac{f(d_{1,n})}{\partial f(d_{1,n})/\partial d_{1,n}}$
 - 7: **end for**
 - 8: Solution $d_1^* = d_{1,N_{\max}+1}$
-

where ψ_2 is a Langrange multiplier constant. Similarly, by performing the partial derivatives of $\Delta_2(\mathbf{d}, \psi_2)$ with respect to d_1, d_2 , and ψ_2 equal to zero, we obtain

$$\begin{cases} \frac{\partial \Delta_2(\mathbf{d}, \psi_2)}{\partial d_1} = \frac{(\theta\sigma^2)^{NT}}{P_S^{NT}} N T \eta d_1^{NT\eta-1} - \psi_2 = 0, & (\mathcal{G}_1), \\ \frac{\partial \Delta_2(\mathbf{d}, \psi_2)}{\partial d_2} = \frac{(\theta\sigma^2)^M}{P_{\mathcal{R}_b}^M M!} M \eta d_2^{M\eta-1} - \psi_2 = 0, & (\mathcal{G}_2), \\ \frac{\partial \Delta_2(\mathbf{d}, \psi_2)}{\partial \psi_1} = d_1 + d_2 - D = 0, & (\mathcal{G}_3). \end{cases} \quad (51)$$

By considering $(\mathcal{G}_1) - (\mathcal{G}_2)$, we get

$$d_2 = \left(\frac{(\theta\sigma^2)^{NT} N T P_{\mathcal{R}_b}^M M!}{(\theta\sigma^2)^M M P_S^{NT}} \right)^{\frac{1}{M\eta-1}} d_1^{\frac{NT\eta-1}{M\eta-1}}. \quad (52)$$

Subsequently, by inserting (52) into $(\mathcal{G}_3)$, we obtain

$$d_1 + \mathcal{Z}_2 d_1^{\frac{NT\eta-1}{M\eta-1}} = D, \quad (53)$$

where $\mathcal{Z}_2 = \left(\frac{(\theta\sigma^2)^{NT} N T P_{\mathcal{R}_b}^M M!}{(\theta\sigma^2)^M M P_S^{NT}} \right)^{\frac{1}{M\eta-1}}$. Similar to (42), (53)

also has a unique solution. By utilizing **Proposition 4**, we design **Algorithm 2** to determine the optimal solution d_1^* for (53). Eventually, we replace the obtained d_1^* from **Algorithm 2** into $(\mathcal{G}_3)$, which yields

$$d_2^* = D - d_1^*. \quad (54)$$

Remark 4. For a special case with $NT = M$, the optimal RL configuration is given by

$$\begin{cases} d_1^* = D \left(1 + (M!)^{\frac{1}{M\eta-1}} \left(\frac{P_{\mathcal{R}_b}}{P_S} \right)^{\frac{M}{M\eta-1}} \right)^{-1}, \\ d_2^* = D - d_1^*. \end{cases} \quad (55)$$

Remark 5. It is worth noting that, from the derived optimal distances given in this part, we can easily indicate the optimal relay coordination. Specifically, the optimal distances can be expressed as

$$d_1^* = \sqrt{(x_{\mathcal{R}}^* - x_S^*)^2 + (y_{\mathcal{R}}^* - y_S^*)^2}, \quad (56)$$

$$d_2^* = \sqrt{(x_{\mathcal{D}}^* - x_{\mathcal{R}}^*)^2 + (y_{\mathcal{D}}^* - y_{\mathcal{R}}^*)^2}, \quad (57)$$




Fig. 2. The performance comparison between the FDF and SDF schemes, where $N = 2$ and $M = 3$.

where (x_S^*, y_S^*) , $(x_{\mathcal{R}}^*, y_{\mathcal{R}}^*)$, and $(x_{\mathcal{D}}^*, y_{\mathcal{D}}^*)$ denote the coordinations of the source, relays, and destination, respectively. Because of the linear topology assumption, $|y_{\mathcal{R}}^* - y_S^*| = |y_{\mathcal{D}}^* - y_{\mathcal{R}}^*| = 0$. Accordingly, d_1^* and d_2^* are simplified to $d_1^* = |x_{\mathcal{R}}^* - x_S^*|$ and $d_2^* = |x_{\mathcal{D}}^* - x_{\mathcal{R}}^*|$, respectively. In such a scenario, a system of 3 linear equations is represented in a matrix multiplication form as $\mathbf{A}\mathbf{x} = \mathbf{b}$, where

$$\mathbf{A} = \begin{bmatrix} -1 & 1 & 0 \\ 0 & -1 & 1 \\ 1 & 0 & -1 \end{bmatrix}, \mathbf{x} = \begin{bmatrix} x_S^* \\ x_{\mathcal{R}}^* \\ x_{\mathcal{D}}^* \end{bmatrix}, \text{ and } \mathbf{b} = \begin{bmatrix} d_1^* \\ d_2^* \\ -D \end{bmatrix}. \quad (58)$$

Because all row vectors of $\mathbf{A}$ are linearly independent, the determinant of $\mathbf{A}$ becomes zero, which implies that the inverse of $\mathbf{A}$, denoted by $\mathbf{A}^{-1}$, exists. As a result, the optimal relay coordination is determined as $\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}$.

V. SIMULATION RESULTS AND DISCUSSION

In this section, we perform Monte Carlo simulations to verify our theoretical analysis presented in the previous sections.

A. Performance Evaluation

For parameter settings, we assume the information with $\beta = 256$ bits, blocklength $k = 256$ CUs, and pathloss exponent $\eta = 3$. We consider the asymmetric system with $d_1 = 0.7 \cdot D$, $d_2 = 0.3 \cdot D$, $P_S = 0.7 \cdot P_0$, and $P_{\mathcal{R}_b} = 0.3 \cdot P_0$. The normalized transmission distance $D = 10$ is assumed.

First, we compare the e2e BLER between the FDF and SDF schemes, as shown in Fig. 2. Here, $N = 2$ and $M = 3$ are assumed for the parameter settings. In this figure, we observe that although the e2e BLERs of the SDF and FDF schemes are identical in the medium and high-SNR regimes, their performance, however, is different in the low-SNR range. In particular, the performance of FDF is better than that of the SDF scheme in the low-SNR regime. Consequently, we will only consider the FDF scheme for the later figures. In addition, the




Fig. 3. The e2e BLER versus the number of source antennas T , where $N = 2$ and $M = 3$.

influence of the number of source antennas T on the e2e BLER is also depicted with some typical values of $T = 1, 2$, and 3 . It is clear that the performance improvement is significant only when T goes from 1 to 2, whereas even in the low-SNR regime, there is a negligible gap in the case of $T = 3$ compared to that of $T = 2$. When $\bar{\gamma}$ gets sufficiently high, the e2e BLERs with $T = 2$ and $T = 3$ are entirely identical, which yields that the value of T should be conservatively chosen to balance the tradeoff between the cost implementation and performance. To see this behavior in the wider range of T , Fig. 3 is dominated. Importantly, the simulation results completely coincide with the theoretical analysis results, which confirm the correctness of our analysis.

Fig. 3 is dedicated to investigating the effect of T on the system performance, where $N = 2$, $M = 3$, and $\bar{\gamma} = 10, 15, 20$ dB are assumed. As observed in Fig. 3, the e2e BLER becomes saturated when $T \geq 2$. As a result, $T = 2$ is an efficient choice to balance the tradeoff between the performance and cost of implementation. One way to improve the system performance as expected is by increasing the average transmit SNR $\bar{\gamma}$, as shown in Fig. 3. However, the transmit power is usually limited in practice; and even when the transmit power can be increased as much as possible, it can cause interference with the other propagation channels. Meanwhile, increasing the number of relays N and destination antennas M can be considered as an alternative way to significantly improve the system performance, which is illustrated in Fig. 4.

Fig. 4 investigates the effect of the number of relays and destination antennas on the system BLER, which is presented in three-dimensional space. Each plane represents the BLER analysis result with a specific average transmit SNR, where we consider three levels of $\bar{\gamma}$ as 5 dB, 10 dB, and 15 dB. Here, $T = 2$ is assumed. The simulation results, which are presented by dots, are math well with the analysis plane. As seen in Fig. 4, the e2e BLERs dramatically drop when $\bar{\gamma}$, N , and M increase, as expected. We note that, as stated in **Proposition 2**, the diversity gain of the proposed system is dependent on the design of the number of relays, source antennas, and destination antennas, which yields the important role of the designed numbers of




Fig. 4. The influence of the number of relays and destination antennas on the system performance, where $T = 2$.




Fig. 5. The effect of blocklength k on the e2e BLER, where $T = 2$, $N = 4$, and $M = 3$.

relays and antennas for the network.

Subsequently, Fig. 5 shows the effect of blocklength on the system performance in three typical cases of average SNRs as 10 dB, 15 dB, and 20 dB, where the parameters of $T = 2$, $N = 4$, and $M = 3$ are set. In Fig. 5, we recognize that the system performance is improved by increasing the average SNR and blocklength. However, we note that the longer blocklength also causes the higher e2e latency, as depicted in Fig. 8. This tradeoff on the blocklength value should be conservatively considered. For example, for a given average SNR $\bar{\gamma} = 20$ dB, to ensure the reliability requirement in the order of e2e BLER of 10^{-5} , the blocklength of 450 CUs can be chosen.

Fig. 6 depicts the suitability between the approximated and asymptotic BLERs. Here, the results are derived for the scenario of $T = 2$, $N = 4$, $M = 3$, and $k = 256, 512, 1024$ CUs. As seen in Fig. 6, the e2e BLER is decreased when increasing $\bar{\gamma}$ and k . The theoretical analysis and simulation curves converge with the asymptotic one in the high-SNR regime. Furthermore,




Fig. 6. The suitability between the approximated and asymptotic BLERs as a function of average SNR $\bar{\gamma}$ in dB with $T = 2$, $N = 4$, and $M = 3$.




Fig. 7. The influence of the e2e latency and throughput on the blocklength, where $T = 2$, $N = 4$, $M = 3$, and $\bar{\gamma} = 20$ dB.

the second asymptotic approach is considered as a validated strategy of the first asymptotic one, where they are in a good agreement with each other.

Eventually, in Fig. 7, we can observe the system performance in terms of the e2e latency and throughput that are the crucial evaluation parameters in the uRLLC requirements, where $T = 2$, $N = 4$, $M = 3$, $\bar{\gamma} = 20$ dB, and $\alpha = 0.5, 1.5, 2.5$ are assumed. While increasing blocklength can improve the reliability, they suffer from the higher latency and throughput. Besides that, Fig. 7 also yields the impact of the decoding delay factor. Specifically, with the higher value of α , the system performance is negatively affected in terms of the e2e latency and throughput. We note that, for a CU duration of $3 \mu\text{s}$ [6], $\alpha = 1.5$, and the parameter settings given in Fig. 7, if we choose the blocklength of $k = 450$ CUs, the system will suffer from the latency of around 2250 CUs corresponding to 6.75 ms (< 10 ms), which satisfies the low-latency constraint of uRLLCs to serve factory-act applications [6].




Fig. 8. The performance comparison between the optimal and non-optimal PA configurations.

B. Performance Evaluation of Optimization Strategies

In this subsection, we compare the system performance of the optimal and non-optimal configurations for PA and RL. For a fair comparison, $\beta = 256$ bits, blocklength $k = 256$ CUs, normalized transmit distance $D = 1$, and pathloss exponent $\eta = 3$ are set in this subsection. The general case for T , N , and M settings is considered with $T = 2$, $N = 3$, and $M = 4$. Furthermore, we also show the optimization performance in a special case with $T = 1$ and $N = M = 2$, where the optimal configurations of PA and RL are dominated in (47) and (55).

Fig. 8 shows the performance comparison between the optimal and non-optimal PA configurations in both the general and special cases of N and M . In this scheme, the distance with $d_1 = 0.7 \cdot D$ and $d_2 = 0.3 \cdot D$ are fixed, as assumed in Section V-A. To highlight the outstanding performance of the optimal PA configuration designed in Section IV-A, we consider the non-optimal scheme with the equal PA, i.e., $P_S = P_{R_b} = 0.5 \cdot P_0$. Fig. 8 reveals that the optimal PA performance is significantly higher than that of the non-optimization in the entire range of the average transmit SNR for both the general and special cases. For e2e BLER of 10^{-5} , the array gains of 2.5 dB are achieved in both the ($T = 1, N = M = 2$) and ($T = 2, N = 3, M = 4$) cases.

In the performance comparison for RL configurations, we assume that the power allocation is fixed with $P_S = 0.7 \cdot P_0$ and $P_{R_b} = 0.3 \cdot P_0$, as assumed in Section V-A. In Fig. 9, the RL optimization designed in Section IV-B is compared to the performance of the non-optimal RL scheme with $d_1 = d_2 = 0.5 \cdot D$. First, we recognize that the performance behavior shown in Fig. 9 is the same as Fig. 8, which confirms the superior performance of the designed optimal RL configuration. However, the array gains achieved in Fig. 9 are much higher than that of Fig. 8. Specifically, for e2e BLER of 10^{-5} , the array gains of 6.25 dB and 9.5 dB are achieved with the ($T = 1, N = M = 2$) and ($T = 2, N = 3, M = 4$) cases, respectively.




Fig. 9. The performance comparison between the optimal and non-optimal RL configurations.

VI. CONCLUSIONS

In this paper, we have investigated SPCs for the dual-hop DF relaying system. The proposed relay network is beneficial in the context of limited transmit power and co-channel noise degradation, whereas the SPC framework is considered to achieve uRLLCs. Besides that, the TAS, PRS, and MRC techniques are utilized at the corresponding terminals to exploit the diversity gain of the proposed system. In the quasi-static Rayleigh fading channels and finite-blocklength regime, the approximated e2e BLERs for both the SDF and FDF schemes are derived from the closed-form expression, from which the e2e latency and throughput are also investigated to provide a performance overview of both ultra-reliability and low-latency. Subsequently, the asymptotic e2e BLER is considered to get more insights into the performance behavior in the high-SNR regime. Furthermore, two optimization strategies of PA and RL are analyzed to minimize the e2e BLER objective function under the system constraints. The results have shown that the BLERs of the SDF and FDF schemes are identical in the average and high-SNR regimes but different in the low-SNR range. Besides that, two asymptotic approaches for the e2e BLER are well matched with each other. The simulation and analysis results are also in good agreement and converge to the asymptotic curve in the high-SNR regime, which validates the correctness of our analysis. Most importantly, the performance of the designed PA and RL optimization schemes is significantly better than the non-optimal configuration.

REFERENCES

- [1] M. Carugi, "Key features and requirements of 5G/IMT-2020 networks," [Online]. Available: <https://www.Internetsociety.org>.
- [2] J. Navarro-Ortiz *et al.*, "A survey on 5G usage scenarios and traffic models," *IEEE Commun. Surveys Tuts.*, vol. 22, no. 2, pp. 905–929, Feb. 2020.
- [3] N. N. Dao *et al.*, "Survey on aerial radio access networks: Toward a comprehensive 6G access infrastructure," *IEEE Commun. Surveys Tuts.*, vol. 23, no. 2, pp. 1193–1225, Feb. 2021.

- [4] K. I. Pedersen, F. Frederiksen, G. Berardinelli, and P. E. Mogensen, "The coverage-latency-capacity dilemma for TDD wide area operation and related 5G solutions," in *Proc. IEEE VTC*, May 2016, pp. 1–5.
- [5] P. Popovski *et al.*, "Wireless access for ultra-reliable low-latency communication: Principles and building blocks," *IEEE Net.*, vol. 32, no. 2, pp. 16–23, Mar.–Apr. 2018.
- [6] O. L. A. López, E. M. G. Fernández, R. D. Souza, and H. Alves, "Ultra-reliable cooperative short-packet communications with wireless energy transfer," *IEEE Sensors J.*, vol. 18, no. 5, pp. 2161–2177, Apr. 2018.
- [7] Y. Polyanskiy, H. V. Poor, and S. Verdú, "Channel coding rate in the finite blocklength regime," *IEEE Trans. Inf. Theory*, vol. 56, no. 5, pp. 2307–2359, May 2010.
- [8] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multiple-antenna fading channels at finite blocklength," *IEEE Trans. Inf. Theory*, vol. 60, no. 7, pp. 4232–4265, Apr. 2014.
- [9] X. Sun, S. Yan, N. Yang, Z. Ding, C. Shen, and Z. Zhong, "Short-packet downlink transmission with non-orthogonal multiple access," *IEEE Trans. Wireless Commun.*, vol. 17, no. 7, pp. 4550–4564, 2018.
- [10] J. Zeng *et al.*, "Enabling ultrareliable and low-latency communications under shadow fading by massive MU-MIMO," *IEEE Internet Things J.*, vol. 7, no. 1, pp. 234–246, Jan. 2020.
- [11] T. Cover and A. E. Gamal, "Capacity theorems for the relay channel," *IEEE Trans. Inf. Theory*, vol. 25, no. 5, pp. 572–584, Sep. 1979.
- [12] Y. Gu, H. Chen, Y. Li, and B. Vucetic, "Ultra-reliable short-packet communications: Half-duplex or full-duplex relaying?" *IEEE Wireless Commun. Lett.*, vol. 7, no. 3, pp. 348–351, 2017.
- [13] Y. Yang, Y. Song, and F. Cao, "HARQ assisted short-packet communications for cooperative networks over Nakagami- m fading channels," *IEEE Access*, vol. 8, pp. 151 171–151 179, Aug. 2020.
- [14] B. Makki and M.-S. Alouini, "End-to-end performance analysis of delay-sensitive multi-relay networks," *IEEE Commun. Lett.*, vol. 23, no. 12, pp. 2159–2163, Dec. 2019.
- [15] N. H. Tu and K. Lee, "Performance analysis and optimization of multihop MIMO relay networks in short-packet communications," *IEEE Trans. Wireless Commun.*, vol. 21, no. 6, pp. 4549–4562, Jun. 2022.
- [16] V. N. Q. Bao and T. T. Thanh, "Performance analysis of partial relay selection networks with short packet communications," in *Proc. IEEE NICS*. IEEE, Dec. 2019, pp. 23–26.
- [17] I. Krikidis, J. Thompson, S. McLaughlin, and N. Goertz, "Amplify-and-forward with partial relay selection," *IEEE Commun. Lett.*, vol. 12, no. 4, pp. 235–237, 2008.
- [18] V. N. Q. Bao and H. Y. Kong, "Diversity order analysis of dual-hop relaying with partial relay selection," *IEICE Trans. Commun.*, vol. 92, no. 12, pp. 3942–3946, 2009.
- [19] A. Goldsmith, *Wireless Communications*. Cambridge University Press, 2005.
- [20] B. Makki, T. Svensson, and M. Zorzi, "Finite block-length analysis of the incremental redundancy HARQ," *IEEE Wireless Commun. Lett.*, vol. 3, no. 5, pp. 529–532, Aug. 2014.
- [21] P. C. Sofotasios and S. Freear, "Novel expressions for the marcum and one dimensional Q-functions," in *Proc. IEEE ISWCS*, 2010.
- [22] I. S. Gradshteyn and I. M. Ryzhik, *Table of integrals, series, and products*. Academic press, 2014.
- [23] M. Khafagy, A. Ismail, M.-S. Alouini, and S. Aissa, "On the outage performance of full-duplex selective decode-and-forward relaying," *IEEE Commun. Lett.*, vol. 17, no. 6, pp. 1180–1183, 2013.
- [24] G. Farhadi and N. C. Beaulieu, "Fixed relaying versus selective relaying in multi-hop diversity transmission systems," *IEEE Trans. Commun.*, vol. 58, no. 3, pp. 956–965, 2010.
- [25] D. Gündüz, M. A. Khojastepour, A. Goldsmith, and H. V. Poor, "Multi-hop MIMO relay networks: Diversity-multiplexing trade-off analysis," *IEEE Trans. Wireless Commun.*, vol. 9, no. 5, pp. 1738–1747, May 2010.
- [26] B. Makki, T. Svensson, G. Caire, and M. Zorzi, "Fast HARQ over finite blocklength codes: A technique for low-latency reliable communication," *IEEE Trans. Wireless Commun.*, vol. 18, no. 1, pp. 194–209, 2018.
- [27] S. S. Rao, *Engineering optimization: theory and practice*. John Wiley & Sons, 2019.
- [28] B. Software, "Root finding – Method comparison." [Online]. Available: <https://mmiranda96blog.wordpress.com/2017/03/08/root-finding-method-comparison/>



Nguyen Thi Yen Linh received B.Sc and M.Sc degrees in Applied Physics from Vietnam National University, Ho Chi Minh (VNUHCM) in 2004 and 2008, respectively. In 2009, she joined the Department of Faculty of Fundamental Science, Posts and Telecommunications Institute of Technology (PTIT), as a Lecturer. Now, she is working toward the Ph.D degree in the Faculty of Electrical and Electronics Engineering with Ho Chi Minh City University of Technology and Education (HCMUTE). Her major research interests are random wireless network, short packet communications, cooperative communications, cognitive radio, physical layer security and machine learning for wireless communication.



Ngo Hoang Tu received the B.S. degree in Computer Networking and Data Communications from Ho Chi Minh City University of Transport (UT-HCMC), Vietnam, in 2020. He is currently pursuing his M.S. degree in the Department of Smart Energy Systems at Seoul National University of Science and Technology, South Korea. From January 2019 to January 2020, he worked as an Assistant Researcher with the Wireless Communication Laboratory, the Posts and Telecommunications Institute of Technology (PTIT), Vietnam. From February 2020 to August 2020, he was a Lecturer with the Department of Computer Engineering, UT-HCMC, Vietnam. His research interests include the cognitive radio, relay networks, MIMO systems, short-packet communications, and 6G infrastructures.



Pham Ngoc Son received the B.E. degree (2005) and M.Eng. degree (2009) in Electronics and Telecommunications Engineering from Post and Telecommunication Institute of Technology, Ho Chi Minh City and Ho Chi Minh City University of Technology, Vietnam, respectively. In 2015, he received the Ph.D. degree in Electrical Engineering from University of Ulsan, South Korea. He is currently a Lecturer in the Faculty of Electrical and Electronics Engineering of Ho Chi Minh City University of Technology and Education (HCMUTE). His major research interests are cooperative communication, cognitive radio, physical layer security, energy harvesting, non-orthogonal multiple access, intelligent reflecting surface and short packet communications.



Vo Nguyen Quoc Bao (Senior Member, IEEE) (M'11—SM'16) served as the Dean of the Faculty of Telecommunications and the Director of the Wireless Communication Laboratory. He is currently an Associate Professor of Wireless Communications with the Posts and Telecommunications Institute of Technology, Vietnam. He has authored over 200 journal and conference articles that have over 2700 citations and H-index of 25. His research interests include wireless communications and information theory with current emphasis on MIMO systems, cooperative and cognitive communications, physical layer security, and energy harvesting. He is a member of the Executive Board of the Radio-Electronics Association of Vietnam and the Electronics Information and Communications Association Ho Chi Minh City. He served as the Technical Program Co-Chair of ATC (2013 and 2014), NAFOSTED, NICS (2014, 2015, and 2016), REV-ECIT 2015, ComManTel (2014 and 2015), and SigTelCom 2017. He is currently serving as a Scientific Secretary of the Vietnam National Foundation for Science and Technology Development Scientific Committee in Information Technology and Computer Science. He is a Technical Editor-in-Chief of REV Journal on Electronics and Communications since 2017, an Associate Editor of the EURASIP Journal on Wireless Communications and Networking, an Editor of the Transactions on Emerging Telecommunications Technologies (Wiley ETT), the VNU Journal of Computer Science and Communication Engineering, and the REV Journal on Electronics and Communications. Mr. Bao's awards and honors include IEEE Exemplary Reviewer for IEEE Wireless Communications in 2013, best paper award at the 9th International Conference on Communications and Networking in China (ChinaCom) in 2014, best paper award at the International Conference on Computing, Management and Telecommunications (ComManTel) in 2013, and outstanding paper award at the 14th International Conference on Advanced Communication Technology (ICACT) in 2012.

DỰ ĐOÁN CÔNG SUẤT TỐI ƯU NGUỒN PHÁT CỦA HỆ THỐNG TRUYỀN GÓI TIN NGẮN QUA MẶT PHẢN XẠ THÔNG MINH BẰNG KỸ THUẬT HỌC SÂU

Nguyễn Thị Yến Linh^{**}, Võ Nguyễn Quốc Bảo^{*}, Phạm Ngọc Sơn^{*}

^{*}Học Viện Công Nghệ Bưu Chính Viễn Thông

^{*}Trường Đại học Sư Phạm Kỹ Thuật Thành Phố Hồ Chí Minh

Tóm tắt- Trong bài báo này, chúng tôi đề xuất mô hình mạng nơ ron sâu để dự đoán công suất tối ưu nguồn phát của hệ thống truyền tin gói ngắn qua mặt phản xạ thông minh phù hợp yêu cầu uRLLCs. Đầu tiên, chúng tôi dẫn ra biểu thức xấp xỉ tỉ lệ lỗi khối qua kênh truyền fading Rayleigh. Dựa trên biểu thức tỉ lệ lỗi khối, chúng tôi tạo tập dữ liệu cho quá trình huấn luyện mạng nơ ron sâu và tiến hành kiểm tra kết quả dự đoán với một tập kiểm thử bất kỳ. Cuối cùng, để đánh giá chất lượng dự đoán của mô hình mạng nơ ron, chúng tôi dựa vào phương pháp đánh giá lỗi trung bình bình phương gốc (RMSE). Kết quả cho thấy rằng RMSE nhỏ (khoảng 10^{-2}) và giá trị này càng giảm khi tăng số lượng mẫu kiểm tra.

Từ khóa- kỹ thuật học sâu, mặt phản xạ thông minh, fading Rayleigh, tỉ lệ lỗi khối, truyền thông gói tin ngắn.

I. GIỚI THIỆU

Trọng tâm của mạng truyền thông không dây thế hệ thứ năm (5G) và mạng không dây thế hệ tiếp theo (6G) là cung cấp dịch vụ đáng tin cậy cho các ứng dụng khác nhau với mục tiêu thiết kế sao cho thông lượng cao, giảm độ trễ đầu cuối và kết nối nhiều thiết bị [1, 2]. Do đó, giao tiếp cực kỳ tin cậy và độ trễ cực thấp (uRLLCs) được xem là yêu cầu chính cần đạt được của các hệ thống mạng không dây thế hệ mới nhằm hỗ trợ các ứng dụng mọi vật kết nối mạng (IoT) như tự động hóa công nghiệp, giao tiếp phương tiện kết nối mọi vật (V2X), thực tế ảo (VR) và thực tế tăng cường (AR) [3]. Dịch vụ uRLLCs yêu cầu nghiêm ngặt cả về độ tin cậy cực cao (99.9999%) và độ trễ phải cực thấp (1ms) [4]. Để đáp ứng yêu cầu cao về độ tin cậy và độ trễ thấp trong uRLLCs, phương thức giao tiếp qua gói tin ngắn được xem như là giải pháp tiềm năng và chỉ được hỗ trợ trong các hệ thống giao tiếp không dây thế hệ mới [5, 6]. Cụ thể, các nghiên cứu gần đây cho thấy sự cải thiện về độ tin cậy và giảm độ trễ của hệ thống giao tiếp qua gói tin ngắn trong mạng chuyển tiếp cộng tác [7-10]. Hơn nữa, gần đây các nhà nghiên cứu còn cho thấy khả năng cải tiến hiệu năng và giảm độ trễ khi nghiên cứu truyền gói tin ngắn kết hợp mặt phản xạ thông minh (IRS)

[11, 12]. So với mạng chuyển tiếp cộng tác AF và DF thì chuyển tiếp qua IRS cải thiện hiệu năng hệ thống [13], mở rộng vùng phủ (tức khoảng cách truyền và nhận tín hiệu từ nguồn đến đích dưới sự hỗ trợ của IRS lớn hơn so với khoảng cách truyền và nhận tín hiệu giữa nguồn và đích qua nút chuyển tiếp), và tiết kiệm công suất phát của nguồn hơn do IRS chỉ đơn thuần phản xạ thụ động tín hiệu mà không cần bổ sung công suất [14, 15]. Hiện nay, để đảm bảo chất lượng dịch vụ cao (QoS) và độ trễ nghiêm ngặt của uRLLC đáp ứng yêu cầu dịch vụ của các hệ thống mạng tương lai, học sâu (DL) được công nhận là một giải pháp khả thi để giải quyết nhiều đề thực tế, chẳng hạn như dự đoán hiệu suất mạng, kiểm soát tắc nghẽn, quản lý hàng đợi và phân bổ tài nguyên cho hệ thống IoE [8]. Đặc biệt, một mô hình của học sâu là mạng nơ ron sâu (DNN). Đây là một trong những mô hình DL tiềm năng được quan tâm để giảm thiểu độ phức tạp tính toán và để đáp ứng các yêu cầu thời gian thực của các hệ thống mạng trong tương lai [16].

A. Các nghiên cứu liên quan

Gần đây, các nhà khoa học đã cho thấy sự cải thiện hiệu năng và giảm độ trễ của giao tiếp gói tin ngắn như trong các bài báo [7-10]. Trong [7], các tác giả chứng tỏ so với truyền gói tin dài thì truyền gói tin ngắn qua nút chuyển tiếp đạt độ tin cậy cao hơn khi xét ở trạng thái kênh truyền hoàn hảo và đạt hiệu năng vượt trội ở giao thức giải mã và chuyển tiếp (DF) như trong [8]. Tiếp tục, bài báo [9] cho thấy độ tin cậy cao của kỹ thuật lựa chọn nút chuyển tiếp bán phần (PRS) để truyền gói tin ngắn trong hệ thống chuyển tiếp DF. Ở bài báo [10] hệ thống đa anten được thiết kế ở nguồn thu và giao thức tỉ số kết hợp cực đại (MRC) được sử dụng nhằm đạt độ phân tập cao, cải thiện hiệu năng truyền gói tin ngắn của hệ thống chuyển tiếp DF. Bên cạnh đó, gần đây mặt phản xạ thông minh đã được chứng minh là một biện pháp hữu hiệu cải tiến hiệu năng hơn hẳn mạng chuyển tiếp. Cụ thể, bài báo [13] cho thấy hiệu năng và độ lợi phân tập của mạng chuyển tiếp qua mặt phản xạ thông minh cải thiện hơn chuyển tiếp qua nút chuyển tiếp DF. Đặc biệt, chuyển tiếp DF có độ lợi phân tập cao hơn chuyển tiếp AF trong truyền tin gói tin dài. Đối với truyền thông tin gói ngắn có sự hỗ trợ của mặt phản xạ thông minh cũng đạt được sự cải tiến vượt bậc. Ở bài báo [11], các tác giả đã chứng minh được truyền tin gói ngắn qua mặt phản xạ thông minh đạt được độ lợi phân tập cao hơn hệ thống chuyển tiếp DF với cùng công suất

Tác giả liên hệ: Nguyễn Thị Yến Linh,

Email: linhnty.ncs@hcmute.edu.vn

Đến tòa soạn: 10/2022, chỉnh sửa: 11/2022, chấp nhận đăng: 12/2022.

nguồn phát. Hay bài báo [12] cho thấy truyền gói tin ngắn qua IRS kết hợp với công nghệ NOMA có hiệu năng vượt trội hơn so với kết hợp giữa IRS và công nghệ đa truy nhập trực giao (OMA) để truyền gói tin ngắn.

Hiện nay, mặc dù nghiên cứu truyền gói tin ngắn qua IRS được các nhà nghiên cứu quan tâm, tuy nhiên số lượng bài báo vẫn còn khá hạn chế. Hầu hết, các tác giả chủ yếu tập trung phân tích sự ảnh hưởng của hiệu năng hệ thống qua tỉ số lỗi khối (BLER) vào các tham số như công suất nguồn phát, số yếu tố phản xạ và độ rộng phổ. Vấn đề tồn tại khi nghiên cứu truyền gói tin ngắn qua IRS trong các hệ thống mạng 5G và thế hệ tiếp theo là làm sao đảm bảo được cả hai yêu cầu về độ tin cậy cao và độ trễ cực thấp uRLLCs. Tức là tìm lời giải cho bài toán tối ưu hệ thống sao cho phải đảm bảo được $BLER \leq 10^{-5}$ và độ trễ nhỏ hơn 1ms. Điều này khó có thể giải quyết bằng phương pháp số thông thường vì hàm mục tiêu cho bài toán tối ưu thường phức tạp và không lồi. Mặt khác, gần đây kỹ thuật học sâu (đặc biệt mạng nơ ron sâu) đã được công nhận là mô hình hiệu quả để giải quyết các thử thách uRLLCs trong mạng không dây thế hệ mới [17] và các hệ thống IoT [18]. Cụ thể, các tác giả trong [19] đề xuất phương pháp học sâu để dự đoán sự phân bố nguồn tài nguyên và lập lịch truy cập uRLLCs cho hệ thống truyền gói tin ngắn. Bài báo cho thấy phương pháp học sâu mang lại kết quả dự đoán chính xác và thời gian thực hiện ngắn phù hợp yêu cầu độ trễ thực của hệ thống 5G. Ở bài báo [20], các tác giả nghiên cứu kỹ thuật học sâu dự đoán BLER và thông lượng truyền gói tin ngắn trong hệ thống mạng nhận thức IoT đa truy nhập không trực giao. Bài báo chứng tỏ kết quả dự đoán từ DNN có độ chính xác cao và độ trễ thấp hơn so với các phương pháp khác, đặc biệt là mô phỏng theo Monte Carlo.

B. Đóng góp chính của bài báo


Dựa trên ưu điểm vượt trội của kỹ thuật học sâu và mặt phản xạ thông minh trong truyền tin gói tin ngắn nhằm đáp ứng yêu cầu cực kỳ nghiêm ngặt về độ tin cậy và độ trễ của hệ thống uRLLCs cho mạng không dây thế hệ tương lai. Đóng góp chính của chúng tôi trong bài báo được liệt kê như sau

- Đầu tiên, chúng tôi đề xuất mô hình truyền thông tin gói ngắn có sự hỗ trợ của mặt phản xạ thông minh. Từ mô hình đề xuất, tỉ số lỗi khối dạng chính xác được dẫn ra để đánh giá hiệu năng cho hệ thống.
- Thứ hai, chúng tôi đề xuất mô hình mạng nơ ron sâu DNN để ước lượng công suất phân bổ nguồn phát cho hệ thống đã đề xuất sao cho đạt yêu cầu uRLLCs.
- Cuối cùng, chúng tôi đề xuất phương pháp đánh giá lỗi trung bình bình phương gốc (RMSE) để đánh giá kết quả dự đoán của mô hình mạng DNN. Qua đó, kết quả của bài báo cho thấy được sự cải tiến vượt trội của phương pháp học sâu dựa trên mô hình DNN về độ chính xác và thời gian thực thi hệ thống.

Về cách trình bày, bài báo được phân bổ như sau. Phần II sẽ trình bày mô hình của hệ thống mạng chuyển tiếp qua mặt IRS và đánh giá hiệu năng hệ thống qua BLER. Mô hình mạng DNN, cách tạo tập dữ liệu và phương pháp đánh giá cho mô hình mạng đề xuất được trình bày trong Phần III. Phần IV, chúng tôi minh chứng sự cải tiến của mô hình mạng đề xuất qua mô phỏng Matlab. Cuối cùng là phần kết luận của bài báo.

II. MÔ HÌNH VÀ ĐÁNH GIÁ HIỆU NĂNG HỆ THỐNG

A. Mô hình



Hình 1. Mô hình truyền gói tin ngắn qua mặt phản xạ thông minh.

Mô hình hệ thống truyền gói tin ngắn qua IRS được mô tả qua Hình 1. Hệ thống bao gồm một nguồn phát sóng (S), một nguồn nhận (D) và một IRS bao gồm N phần tử phản xạ thụ động. Giả sử rằng nguồn S và đích D sử dụng một ăng ten để truyền và nhận tín hiệu. Ở đây, chúng tôi cũng giả sử rằng không có đường truyền trực tiếp giữa nguồn và đích do vật cản từ môi trường. Hơn nữa, kênh truyền giữa nguồn và đích là kênh Rayleigh fading bán tĩnh phẳng.

Bởi vì IRS hoạt động như một bộ phản xạ thông minh, do đó IRS có thể phối hợp, trao đổi thông tin trạng thái kênh từ nguồn và đích thông qua bộ điều khiển không dây [21]. Từ đó IRS có thể điều chỉnh pha của tất cả phần tử phản xạ sao cho tỉ số tín hiệu trên nhiễu nhận tại đích đạt lớn nhất [22]. Mặt khác, do suy hao tín hiệu đáng kể nên chúng tôi bỏ qua tín hiệu phản xạ trên IRS từ hai lần trở lên và chỉ xét tín hiệu phản xạ một lần [23]. Tín hiệu nhận tại đích D được biểu diễn như sau:

$$y_D = \sqrt{P} \left[\sum_{i=1}^N h_i r_i g_i \right] x_D + n_D, \quad (1)$$

với P là công suất phát của nguồn S, x_D là tín hiệu cần truyền đến đích D, n_D là nhiễu Gauss trắng cộng (AWGN) với trung bình 0 và phương sai N_0 . Hơn nữa, $r_i = e^{j\phi_i}$ là hệ số phản xạ được tạo ra bởi yếu tố phản xạ thứ i trong IRS ($i=1,2,...,N$) [13] và ϕ_i là độ dịch chuyển pha của yếu tố phản xạ thứ i trong IRS. Kế tiếp, h_i và g_i là hệ số kênh truyền từ nguồn S đến yếu tố phản xạ thứ i trong IRS và từ yếu tố phản xạ thứ i đến đích D, tương ứng.

$$h_i = d_1^{-\nu/2} \alpha_i e^{-j\theta_i}, \quad (2)$$

$$g_i = d_2^{-\nu/2} \beta_i e^{-j\phi_i}, \quad (3)$$

với α_i và β_i ; θ_i và ϕ_i lần lượt là biên độ và độ dịch pha của hệ số kênh h_i và g_i ; d_1 và d_2 lần lượt là khoảng cách từ nguồn S đến IRS và từ IRS đến đích, tương ứng; ν là hệ số suy hao đường truyền. Chúng tôi cũng giả sử hệ thống giao tiếp được xét trong trường gần, nghĩa là khoảng cách giữa nguồn hoặc đích đến chính giữa IRS nhỏ

hơn $\frac{2L^2}{\lambda}$, với L kích thước cực đại của IRS và λ là bước sóng của tín hiệu truyền [24].

Từ (1), tỉ số tín hiệu trên nhiễu (SNR) tức thời thu được tại đích D được xác định như sau

$$\gamma_D = \frac{P \left| \sum_{i=1}^N \alpha_i \beta_i e^{j(\phi_i - \theta_i - \varphi_i)} \right|^2}{d_1^v d_2^v N_0}. \quad (4)$$

Ở đây, IRS chọn góc dịch chuyển pha $\phi_i = \theta_i + \varphi_i$ sao cho SNR trong (4) đạt giá trị lớn nhất [24]. Do đó, (4) có thể được viết gọn lại như sau

$$\gamma_D = Z^2 \bar{\gamma}, \quad (5)$$

với $Z = \sum_{i=1}^N \frac{\alpha_i \beta_i}{d_1^v d_2^v}$ và $\bar{\gamma} = \frac{P}{N_0}$ là SNR trung bình.

Theo [Định lý 1, 13], từ (5) hàm mật độ xác suất (PDF) và hàm phân phối tích lũy (CDF) của γ có dạng như sau

$$f_\gamma(\gamma) = \frac{1}{2b^{a+1}\Gamma(a+1)\bar{\gamma}^{\frac{a+1}{2}}} \gamma^{\left(\frac{a-1}{2}\right)} \exp\left(-\frac{1}{b}\sqrt{\gamma/\bar{\gamma}}\right), \quad (6)$$

và

$$F_\gamma(\gamma) = \frac{\Upsilon\left(a+1, \frac{1}{b}\sqrt{\frac{\gamma}{\bar{\gamma}}}\right)}{\Gamma(a+1)} \quad (7)$$

$$\stackrel{(i)}{=} 1 - \frac{\Gamma\left(a+1, \frac{1}{b}\sqrt{\frac{\gamma}{\bar{\gamma}}}\right)}{\Gamma(a+1)},$$

với (i) là phép rút gọn sử dụng [25, CT(8356.3)]; hàm gamma và gamma không hoàn chỉnh cận trên được định nghĩa theo [25, CT(8.310.1)] và [25, CT(8.350.2)] như sau

$$\Gamma(\alpha) = \int_0^\infty e^{-t} t^{\alpha-1} dt. \quad (8)$$

$$\Gamma(\alpha, x) = \int_x^\infty e^{-t} t^{\alpha-1} dt. \quad (9)$$

và các tham số

$$a = \frac{\delta_1^2}{\delta_2} - 1, \quad (10)$$

$$b = \frac{\delta_2}{\delta_1}, \quad (11)$$

$$\delta_1 = \frac{N\pi}{4} \sqrt{\frac{1}{d_1^v d_2^v}}, \quad (12)$$

$$\delta_2 = \frac{N}{d_1^v d_2^v} \left(1 - \frac{\pi^2}{16}\right). \quad (13)$$

B. Đánh giá hiệu năng hệ thống

Trong phần này, chúng tôi sử dụng thông số tỉ lệ lỗi khối để đánh giá hiệu năng của hệ thống truyền tin gói ngắn qua IRS.

Chúng tôi giả sử hệ thống truyền ở chế độ X, truyền β bits thông tin qua k kênh sử dụng ($k \geq 100$) với tốc độ truyền $R_x = \frac{\beta_x}{k}$ và có tỷ lệ SNR γ_x .

Theo như trong [26, CT(59)] và [27, CT(4)], tỉ lệ lỗi khối trung bình BLER xấp xỉ ở chế độ X được dẫn ra như sau

$$\bar{\varepsilon}_x \approx \int_0^\infty Q\left(\frac{C(\gamma_x) - R_x}{\sqrt{V(\gamma_x)/k}}\right) f_{\gamma_x}(\gamma) d\gamma, \quad (14)$$

với $C(\gamma_x) = \log_2(1 + \gamma_x)$ là dung lượng kênh

Shannon, $V(\gamma_x) = \left(1 - \frac{1}{(1 + \gamma_x)^2}\right) (\log_2 e)^2$ là độ phân tán

kênh truyền, $Q^{-1}(\cdot)$ là ngược của hàm Q-function với

$Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty \exp\left(-\frac{t^2}{2}\right) dt$ [28], $f_{\gamma_x}(\gamma)$ là hàm mật độ

xác suất của γ_x . Để đơn giản trong việc tính toán, chúng tôi sử dụng xấp xỉ của hàm $Q(\cdot)$ theo [29, CT(14)], cụ thể như sau

$$Q\left(\frac{C(\gamma_x) - R_x}{\sqrt{V(\gamma_x)/k}}\right) \approx \Psi(\gamma_x),$$

với

$$\Psi(\gamma_x) = \begin{cases} 1, & \gamma_x \leq \rho_L, \\ 0.5 - v\sqrt{k}(\gamma_x - \theta), & \rho_L < \gamma_x < \rho_H, \\ 0, & \gamma_x \geq \rho_H, \end{cases} \quad (15)$$

với $v = \left[2\pi(2^{2R_x} - 1)\right]^{-1/2}$, $\theta = 2^{R_x} - 1$,

$$\rho_H = \theta + \frac{1}{2v\sqrt{k}} \text{ và } \rho_L = \theta - \frac{1}{2v\sqrt{k}}.$$

Bằng cách thay (15) vào (14) và thực hiện phép lấy tích phân từng phần, tỉ lệ lỗi khối trung bình BLER thu được như sau

$$\bar{\varepsilon}_x = v\sqrt{k} \int_{\rho_L}^{\rho_H} F_{\gamma_x}(\gamma) d\gamma. \quad (16)$$

Thay (7) vào (16), tỉ lệ lỗi khối toàn trình của hệ thống chuyển tiếp qua IRS thu được như sau

$$\begin{aligned}\bar{\varepsilon} &= v\sqrt{k} \int_{\rho_L}^{\rho_H} F_{\gamma}(\gamma) d\gamma, \\ &= v\sqrt{k} \left[\rho_H - \rho_L - \frac{2}{\Gamma(a+1)} \left(\Delta(\sqrt{\rho_H}) - \Delta(\sqrt{\rho_L}) \right) \right],\end{aligned}\quad (17)$$

với hàm $\Delta(\gamma)$ được đặt như sau

$$\begin{aligned}\Delta(\gamma) &= \frac{1}{2} \left[\gamma^2 \Gamma \left(a+1, \frac{\gamma}{b\sqrt{\gamma}} \right) - \frac{\gamma^{a+2}}{(b\sqrt{\gamma})^a} e^{\frac{-\gamma}{b\sqrt{\gamma}}} \right. \\ &\quad \left. - \frac{(a+2)}{\left(\frac{1}{b\sqrt{\gamma}} \right)^2} \Gamma \left(a+2, \frac{\gamma}{b\sqrt{\gamma}} \right) \right].\end{aligned}\quad (18)$$

Với mục tiêu hướng đến của hệ thống là có thể đáp ứng dịch vụ uRLLCs, do đó chúng tôi quan tâm đến vấn đề tối ưu công suất phân bổ của nguồn sao cho đạt tối ưu. Bài toán tối ưu công suất được viết dưới dạng như sau

$$\min_{\mathbf{P}} \varepsilon(\mathbf{P}) \text{ s.t. } \mathbf{P} \leq \mathbf{P}_0, \quad (19)$$

với $\mathbf{P}_0$ là tổng công suất phân bổ cho nguồn phát.

Từ (17), ta nhận thấy hàm mục tiêu $\varepsilon(\mathbf{P})$ là hàm không lồi. Điều này dẫn đến bài toán tối ưu trong (19) cũng không lồi và khó có thể giải được bằng phương pháp lấy đạo hàm riêng. Để giải quyết khó khăn này, chúng tôi đề xuất kỹ thuật học sâu dựa trên cơ sở xây dựng mạng nơ ron sâu DNN được trình bày trong Phần III.

III. MẠNG NƠ RON SÂU

Trong phần này, chúng tôi đề xuất mạng DNN để giải quyết vấn đề trong (19), tức ước lượng công suất nguồn phát $\hat{P}$ của hệ thống dưới điều kiện ràng buộc tỉ số lỗi khối BLER $\leq 10^{-5}$ phù hợp yêu cầu dịch vụ uRLLCs [30].


A. Mô hình mạng DNN

Mô hình mạng DNN gồm một lớp vào, một lớp ra và $L-1$ lớp ẩn được trình bày qua Hình 2. Lớp vào chứa một neuron tương ứng với một nút chỉ tham số ε . Để có được tham số ε này, chúng tôi sử dụng các giá trị được liệt kê như trong **Error! Reference source not found.** để tính ε thông qua công thức (17). Ở lớp ra của mô hình chứa một neuron tương ứng với nút công suất phát của nguồn $\hat{P}$.

Bảng 1. Giá trị các tham số tính BLER.

Tham số	Giá trị	Tham số	Giá trị
$\bar{\gamma}$	[-10dB, 19dB]	k	200 CUs
N	4	ν	2

d_1	1m	β	256 bits
d_2	1m		



Hình 2. Mô hình mạng nơ ron sâu.

Tiếp theo, để hiểu rõ hơn về mô hình mạng DNN chúng tôi giả sử rằng mô hình chứa $L-1$ lớp ẩn. Mỗi lớp ẩn l với $l=1, \dots, L-1$ có chứa $Q^{(l)}$ nơ ron và nhận hàm kích hoạt Sigmoid. Hàm kích hoạt trong mạng nơ ron được hiểu là hàm ánh xạ các đầu vào của một nút với đầu ra tương ứng [31]. Hàm Sigmoid có nhiều ưu điểm nổi trội hơn so với các hàm kích hoạt khác như tính toán đơn giản và tối ưu dễ dàng, tránh được vấn đề đạo hàm vô cùng nhỏ tại các lớp nơ ron đầu tiên trong quá trình lan truyền ngược (vanishing gradients) [32].

Đầu ra $y^{(l)}$ của lớp thứ l của mô hình DNN được tính như sau [16, CT. (13)]

$$y^{(l)} = g^{(l)} \left(w^{(l)} y^{(l-1)} + b^{(l)} \right), \quad (20)$$

với $g^{(l)}(x) = \frac{1}{1+e^{-x}}$ là hàm kích hoạt, $w^{(l)}$ là trọng số và $b^{(l)}$ ngưỡng dự kiến của của lớp thứ l . Dựa và (20), giá trị đầu ra $\hat{P}$ có thể được tính như sau

$$\hat{P} = G(\varepsilon; \Omega), \quad (21)$$

với $G(\cdot)$ là hàm chưa biết và học được của mạng DNN; ε là vectơ đầu vào và


$\Omega \triangleq \{w^{(l)}, b^{(l)}, l=1, \dots, L-1\}$ là tập hợp các tham số và trọng số của DNN.

Để tạo được mạng DNN chúng tôi tiến hành hai giai đoạn dựa vào mô hình học sâu gồm giai đoạn huấn luyện và giai đoạn dự đoán như **Hình 3**.

Trong giai đoạn huấn luyện, mạng sử dụng thuật toán tối ưu như Levenberg-Marquardt algorithm (LMA). LMA là một trong các thuật toán tối ưu phổ biến trong huấn luyện mạng nơ ron và có tốc độ hội tụ nhanh [33]. Chúng tôi chọn LMA để tối ưu các tham số của mô hình dựa vào tập dữ liệu huấn luyện trong suốt quá trình học ngoại tuyến. Đồng thời, mạng trải qua quá trình lan truyền ngược từng bước xác định hàm mất mát, độ lệch và cập nhật các trọng số.

Sau khi kết thúc quá trình huấn luyện, mạng DNN được tạo ra và có thể được sử dụng cho dự đoán trực tuyến thông qua quá trình dự đoán bất cứ khi nào có thông tin mới ở đầu vào. Vì toàn bộ giai đoạn huấn luyện diễn ra

ngoại tuyến, mạng thiết kế có thể giảm đáng kể độ phức tạp tính toán, chi phí triển khai và thời gian thực hiện [34].



Hình 3. Cấu trúc của các giai đoạn dự đoán và huấn luyện của mô hình học sâu.

B. Tạo lập dữ liệu

Trong phần này chúng tôi trình bày cách tạo ra tập dữ liệu cho quá trình huấn luyện mạng DNN. Đầu tiên, chúng tôi sử dụng các giá trị như trong **Error! Reference source not found.** để tính giá trị BLER ε dựa vào phương trình (17). Để đảm bảo yêu cầu dịch vụ uRLLCs, chúng tôi chọn BLER $\varepsilon = [10^{-7} - 10^{-5}]$ làm biến đầu vào của các mẫu huấn luyện j trong tập dữ liệu M của mạng DNN và được tạo đồng nhất dựa trên kích thước mạng. Tập dữ liệu được tạo M gồm các vectơ đặc trưng đầu vào BLER $\varepsilon^{(j)}$ và đầu ra công suất phát $P^{(j)}$, tương ứng. Tập dữ liệu có thể được biểu diễn như $[\varepsilon^{(j)}, P^{(j)}], j = 1, \dots, M$. Trong mô hình của chúng tôi, tập dữ liệu được tạo ra có 2060 mẫu và được chia 70% cho tập huấn luyện, 30% còn lại chia đều cho tập đánh giá M_{val} và tập kiểm thử M_{tes} .

C. Đánh giá RMSE

Sau khi hoàn thành quá trình huấn luyện, mô hình mạng DNN được tạo ra thông qua một hàm ánh xạ $G(\varepsilon; \Omega)$. Từ hàm G này, quá trình dự đoán giá trị $\hat{P}$ bắt đầu thực hiện với bất kỳ biến đầu vào ε . Chú ý rằng giá trị biến ε thuộc tập dữ liệu M . Để đánh giá tính hiệu quả của mô hình mạng DNN, chúng tôi sử dụng phương pháp đánh giá lỗi trung bình bình phương gốc (RMSE). Theo thống kê học, phương pháp RMSE là một trong những phương pháp hiệu quả để đo độ sai lệch giữa những giá trị dự đoán và giá trị thực tiễn [35]. Phương pháp RMSE dựa trên mô hình DNN của chúng tôi được biểu diễn qua hàm Δ như sau

$$\Delta = \sqrt{\frac{1}{M_{tes}} \sum_{j=1}^{M_{tes}} (P^{(j)} - \hat{P}^{(j)})^2}, \quad (22)$$

với $P^{(j)}$ và $\hat{P}^{(j)}$ là giá trị công suất mong muốn (tức giá trị huấn luyện ban đầu) và công suất dự đoán được từ mô hình DNN.

Ta để ý rằng giá trị Δ tỉ lệ nghịch với tập mẫu kiểm tra M_{tes} (tức sai số Δ càng bé khi M_{tes} càng tăng). Hay nói cách khác mức độ ước lượng kết quả của mô hình DNN của chúng ta càng tin cậy khi Δ càng nhỏ.

IV. KẾT QUẢ MÔ PHỎNG

Trong phần này, chúng tôi trình bày các kết quả mô phỏng để cho thấy hiệu quả của mô hình mạng DNN đã đề xuất qua phần mềm mô phỏng Matlab. Giả sử mô hình truyền gói tin ngắn được xét trong không gian 2D với tọa độ của nguồn S , IRS và đích D là $(0, 0)$, $(1, 0)$ và $(2, 0)$ tương ứng. Tiếp theo, chúng tôi sử dụng các giá trị tham số để tính BLER như giá trị trung bình SNR $\bar{\gamma} = [-10\text{dB}, 19\text{dB}]$, số yếu tố phản xạ $N = 4$, các khoảng cách $d_1 = d_2 = 1\text{m}$, chiều dài gói tin $k = 200\text{CU}$ s, số bits thông tin $\beta = 256\text{bits}$ được liệt kê như trong **Error! Reference source not found.** Chúng tôi nhắc lại

rằng $\bar{\gamma} = \frac{P}{N_0}$ với mật độ nhiễu N_0 được chuẩn hóa bằng


1. Do vậy giá trị công suất phát P trong phần mô phỏng này được xem như cũng chính là giá trị trung bình SNR.

Các thông số cho quá trình huấn luyện mạng DNN được thiết lập gồm số nơ ron trên mỗi lớp chứa 100 nơ ron, tốc độ học 10^{-3} và chu kỳ huấn luyện 1000 epochs. Đặc biệt, chúng tôi tạo được tập dữ liệu 2060 giá trị và chia theo tỉ lệ 70% cho quá trình huấn luyện, 15% cho đánh giá và 15% cho dự đoán kết quả.

Sau quá trình huấn luyện và tạo mạng DNN, chúng tôi thu được các kết quả thông qua mô phỏng minh họa trong các hình từ Hình 4 đến Hình 5.


Đầu tiên, chúng tôi trình bày sự ảnh hưởng của công suất phát P vào BLER hệ thống qua mô hình mạng DNN ở các lớp ẩn lần lượt 1, 2, 4 và 10 lớp như trong Hình 4. Quan sát hình ta thấy rõ rằng BLER càng giảm khi tăng công suất phát P ở trường hợp lý thuyết (đường liền nét) và trường hợp dự đoán từ DNN (các đường nét chấm). Đặc biệt, đường mô phỏng kết quả dự đoán từ DNN khớp hoàn toàn với kết quả lý thuyết ở số lớp ẩn từ 4 và 10 lớp. Ở các lớp ẩn lớn, công suất tăng thì BLER càng giảm dần. Ta biết rằng mạng DNN với nhiều lớp ẩn thì khả năng tạo được tập dữ liệu lớn dẫn tới công suất mạng sẽ cao. Còn ở mô hình mạng DNN 1 lớp không thể học các mẫu phức tạp trong một tập dữ liệu có số chiều lớn [36].

Cụ thể, kết quả dự đoán của mô hình DNN từ 2 lớp ẩn trở đi gần như trùng nhau. Tuy nhiên, ta cần phải cân nhắc việc chọn lựa số lớp ẩn vì số lớp ẩn càng lớn thì dễ gây ra hiện tượng quá khớp với dữ liệu huấn luyện (overfitting). Điều này dễ dẫn đến kết quả không chính xác trên tập kiểm tra. Hơn nữa, Hình 4 cũng cho thấy rõ hệ thống thỏa điều kiện tối ưu như trong (19) thì công suất phát phải đạt $P \geq 12\text{ (dB)}$.



Hình 4. Sự ảnh hưởng công suất dự đoán P so với BLER qua mô hình mạng DNN.

Tiếp theo, chúng tôi đánh giá độ tin cậy của mô hình mạng DNN thông qua chỉ số RMSE như trong Hình 5. Từ Hình 5, ta thấy rằng RMSE phụ thuộc vào số mẫu kiểm tra M (chú ý M thuộc tập kiểm tra M_{tes}). Cụ thể, số mẫu M càng tăng thì RMSE càng giảm. Điều này hoàn toàn phù hợp với lý thuyết theo (25). Hơn nữa, ta cũng thấy rằng giá trị RMSE ở 1 lớp cao hơn ở các lớp lớn hơn. Do đó, kết quả dự đoán từ DNN của 1 lớp sẽ kém tin cậy hơn ở các lớp cao hơn. Số lớp càng tăng thì độ tin cậy càng cao, tức RMSE càng giảm. Bởi vì khi số lớp ẩn quá nhiều thì trong quá trình huấn luyện mạng dễ xảy ra hiện tượng mất đạo hàm (vanishing gradient). Trong quá trình huấn luyện, giá trị đạo hàm là thông tin phản hồi của quá trình lan truyền ngược. Giá trị này trở nên vô cùng nhỏ tại các lớp nơ ron đầu tiên khiến cho việc cập nhật trọng số mạng không thể xảy ra.



Hình 5. Ảnh hưởng RMSE vào số mẫu kiểm tra M và số lớp ẩn.

Qua đó, ta thấy rằng để kết quả dự đoán đạt được độ tin cậy cao thì phải tăng số mẫu thử và chọn số lớp ẩn phù hợp. Tuy nhiên, việc tăng số lớp ẩn cần phải cân nhắc vì sẽ ảnh hưởng đến thời gian thực thi hệ thống thông qua

Chúng ta có thể thấy được rằng thời gian thực thi của quá trình dự đoán qua kỹ thuật học sâu dựa vào mạng DNN cực kỳ ngắn so với mô phỏng quá trình tính toán lý thuyết.

Tuy nhiên, số lớp ẩn càng lớn thì thời gian thực thi mô phỏng cũng tăng theo. Do vậy, để đảm bảo yêu cầu độ trễ của dịch vụ uRLLCs ($\leq 1\text{ms}$), lớp ẩn tối ưu thực thi của hệ thống mạng truyền gói tin ngắn của chúng tôi được chọn là 4 lớp ẩn.

Bảng 2. So sánh thời gian thực thi mô phỏng lý thuyết và mạng DNN của hệ thống.

Loại	Thời gian thực hiện
Lý thuyết	1.712116 (s)
DNN- 1 lớp	0.00627 (s)
DNN- 2 lớp	0.00703(s)
DNN- 4 lớp	0.007707(s)
DNN-10 lớp	0.017568(s)

V. KẾT LUẬN

Trong bài báo này, chúng tôi đã đề xuất kỹ thuật học sâu, dựa vào mô hình DNN để dự đoán công suất tối ưu cho nguồn phát sao cho đạt uRLLCs cho hệ thống truyền gói tin ngắn qua mặt phản xạ thông minh IRS. Các kết quả bài báo cho thấy được giá trị công suất được dự đoán từ mô hình mạng DNN trùng khớp với giá trị công suất được huấn luyện ở các lớp ẩn như 2, 4 và 10 lớp. Hơn nữa, giá trị RMSE càng giảm khi số mẫu kiểm tra và số lớp ẩn tăng. Nói một cách khác, kết quả dự đoán từ DNN đạt độ tin cậy khi tăng số mẫu kiểm tra và tăng số lớp ẩn. Tuy nhiên, chúng ta cần cân nhắc khi tăng số lớp ẩn quá nhiều sẽ ảnh hưởng đến độ trễ của hệ thống do thời gian thực thi hệ thống mạng tăng và giảm độ tin cậy của hệ thống. Để đáp ứng yêu cầu uRLLCs lớp ẩn tối ưu cho hệ thống của chúng tôi được chọn là 4 lớp.

LỜI CẢM ƠN

Nghiên cứu này được hỗ trợ bởi các nghiên cứu viên tại Phòng thí nghiệm thông tin vô tuyến và được tài trợ bởi Học Viện Công nghệ Bưu Chính Viễn Thông dưới mã số 08-HV-2022-RD_CB2.

TÀI LIỆU THAM KHẢO

- [1] J. Sachs, G. Wikstrom, T. Dudda, R. Baldemair, and K. Kittichokechai, "5G radio network design for ultra-reliable low-latency communication," *IEEE Network*, vol. 32, no. 2, pp. 24-31, 2018.
- [2] S. Zhang, X. Xu, Y. Wu, and L. Lu, "5G: Towards energy-efficient, low-latency and high-reliable communications networks," in *2014 IEEE international conference on communication systems*, 2014, pp. 197-201: IEEE.
- [3] S. Krishna Sharma and X. Wang, "Towards Massive Machine Type Communications in Ultra-Dense Cellular IoT Networks: Current Issues and Machine Learning-Assisted Solutions," *arXiv e-prints*, p. arXiv: 1808.02924, 2018.
- [4] P. Schulz et al., "Latency critical IoT applications in 5G: Perspective on the design of radio interface and network

- architecture," *IEEE Communications Magazine*, vol. 55, no. 2, pp. 70-78, 2017.
- [5] G. Durisi, T. Koch, and P. Popovski, "Toward massive, ultrareliable, and low-latency wireless communication with short packets," *Proceedings of the IEEE*, vol. 104, no. 9, pp. 1711-1726, 2016.
- [6] Y. Polyanskiy, H. V. Poor, and S. Verdú, "Channel coding rate in the finite blocklength regime," *IEEE Transactions on Information Theory*, vol. 56, no. 5, p. 2307, 2010.
- [7] Y. Hu, A. Schmeink, and J. Gross, "Relaying with finite blocklength: Challenge vs. opportunity," in *2016 IEEE Sensor Array and Multichannel Signal Processing Workshop (SAM)*, 2016, pp. 1-5: IEEE.
- [8] P. Nouri, H. Alves, R. D. Souza, and M. Latva-aho, "Ultra-reliable short message cooperative relaying protocols under Nakagami-m fading," in *2017 International Symposium on Wireless Communication Systems (ISWCS)*, 2017, pp. 287-292: IEEE.
- [9] V. N. Q. Bao and T. T. Thanh, "Performance Analysis of Partial Relay Selection Networks with Short Packet Communications," *The 6th NAFOSTED Conference on Information and Computer Science (NICS)*, pp. 23-26, 2019.
- [10] N. T. Y. Linh, N. H. Tú, and V. N. Q. Bảo, "Đánh Giá Hiệu Năng Mạng Chuyển Tiếp Từng Phần Với Đa Anten Thu Trong Truyền Thông Gói Tin Ngắn," *Journal of Science and Technology on Information and Communications*, vol. 1, no. 4A, pp. 53-61, 2020.
- [11] V. N. Q. B. Nguyễn Thị Yến Linh, Phạm Ngọc Sơn, "Phân Tích Độ Lợi Phân Tập Cho Mạng Chuyển Tiếp Qua Mặt Phản Xạ Thông Minh Và Nút Chuyển Tiếp Trong Truyền Thông Gói Tin Ngắn," *Journal of Science and Technology on Information and Communications (JSTIC)*, vol. 01, no. 04B, pp. 56-64, 2021 2021.
- [12] T.-H. Vu, T.-V. Nguyen, D. B. Da Costa, and S. Kim, "Intelligent Reflecting Surface-Aided Short-Packet Non-Orthogonal Multiple Access Systems," *IEEE Transactions on Vehicular Technology*, 2022.
- [13] A.-A. A. Boulogeorgos and A. Alexiou, "Performance Analysis of Reconfigurable Intelligent Surface-Assisted Wireless Systems and Comparison With Relaying," *IEEE Access*, vol. 8, pp. 94463-94483, 2020.
- [14] L. Yang, Y. Yang, M. O. Hasna, and M.-S. Alouini, "Coverage, Probability of SNR Gain, and DOR Analysis of RIS-Aided Communication Systems," *IEEE Wireless Communications Letters*, 2020.
- [15] E. Basar, M. Di Renzo, J. De Rosny, M. Debbah, M.-S. Alouini, and R. Zhang, "Wireless communications through reconfigurable intelligent surfaces," *IEEE Access*, vol. 7, pp. 116753-116773, 2019.
- [16] C. Zhang, P. Patras, and H. Haddadi, "Deep learning in mobile and wireless networking: A survey," *IEEE Communications surveys & tutorials*, vol. 21, no. 3, pp. 2224-2287, 2019.
- [17] A. Salh *et al.*, "A Survey on Deep Learning for Ultra-Reliable and Low-Latency Communications Challenges on 6G Wireless Systems," *IEEE Access*, vol. 9, pp. 55098-55131, 2021.
- [18] Q. Mao, F. Hu, and Q. Hao, "Deep learning for intelligent wireless networks: A comprehensive survey," *IEEE Communications Surveys & Tutorials*, vol. 20, no. 4, pp. 2595-2621, 2018.
- [19] M. Y. Abdelsadek, Y. Gadallah, and M. H. Ahmed, "Resource Allocation of URLLC and eMBB Mixed Traffic in 5G Networks: A Deep Learning Approach," in *GLOBECOM 2020-2020 IEEE Global Communications Conference*, 2020, pp. 1-6: IEEE.
- [20] T.-H. Vu, T.-V. Nguyen, T.-T. Nguyen, and S. Kim, "Performance Analysis and Deep Learning Design of Wireless Powered Cognitive NOMA IoT Short-Packet Communications with Imperfect CSI and SIC," *IEEE Internet of Things Journal*, 2021.
- [21] X. Tan, Z. Sun, J. M. Jornet, and D. Pados, "Increasing indoor spectrum sharing capacity using smart reflect-array," in *2016 IEEE International Conference on Communications (ICC)*, 2016, pp. 1-6: IEEE.
- [22] Q. Wu and R. Zhang, "Intelligent reflecting surface enhanced wireless network via joint active and passive beamforming," *IEEE Transactions on Wireless Communications*, vol. 18, no. 11, pp. 5394-5409, 2019.
- [23] Q. Wu and R. Zhang, "Towards Smart and Reconfigurable Environment: Intelligent Reflecting Surface Aided Wireless Network," *IEEE Communications Magazine*, vol. 58, no. 1, pp. 106-112, 2020.
- [24] W. Tang *et al.*, "Wireless communications with reconfigurable intelligent surface: Path loss modeling and experimental measurement," *IEEE Transactions on Wireless Communications*, 2020.
- [25] I. S. Gradshteyn and I. M. Ryzhik, *Table of integrals, series, and products*. Academic press, 2014.
- [26] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multipleantenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, p. 4232, 2014.
- [27] Yuehua Yu, He Chen , Yonghui Li, Zhiguo Ding , and Branka Vucetic, "On the Performance of Non-Orthogonal Multiple Access in Short-Packet Communications," *IEEE Communications Letters*, vol. 22, no. 3, pp. 590-593, 2018.
- [28] P. C. S. S. Freear, "Novel expressions for the Marcum and one dimensional Q-functions," *2010 7th International Symposium on Wireless Communication Systems*, 19-22 Sept. 2010.
- [29] B. Makki, T. Svensson, and Z. Michele, "Finite Block-Length Analysis of the Incremental Redundancy HARQ," *IEEE Wireless Commun. Lett.*, vol. 3, no. 5, pp. 529-532, Oct. 2014.
- [30] P. Popovski *et al.*, "Wireless access for ultra-reliable low-latency communication: Principles and building blocks," *Ieee Network*, vol. 32, no. 2, pp. 16-23, 2018.
- [31] S. Sharma, S. Sharma, and A. Athaiya, "Activation functions in neural networks," *towards data science*, vol. 6, no. 12, pp. 310-316, 2017.
- [32] D.-A. Clevert, T. Unterthiner, and S. Hochreiter, "Fast and accurate deep network learning by exponential linear units (elus)," *arXiv preprint arXiv:1511.07289*, 2015.
- [33] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [34] C. D. Ho, T.-V. Nguyen, T. Huynh-The, T.-T. Nguyen, D. B. da Costa, and B. An, "Short-packet communications in wireless-powered cognitive IoT networks: Performance analysis and deep learning evaluation," *IEEE Transactions on Vehicular Technology*, vol. 70, no. 3, pp. 2894-2899, 2021.
- [35] W. Wang and Y. Lu, "Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model," in *IOP conference series: materials science*

and engineering, 2018, vol. 324, no. 1, p. 012049: IOP Publishing.

[36] T. O'shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Transactions on Cognitive Communications and Networking*, vol. 3, no. 4, pp. 563-575, 2017.

DEEP LEARNING BASED THE TRANSMIT POWER PREDICTION FOR INTELLIGENT REFLECTING SURFACE-ASSISTED SHORT PACKET COMMUNICATIONS

Abstract: In this paper, we propose a deep neural network model to predict the transmit power of the source for intelligent reflecting surface-assisted short packet communications that meets the extremely high reliability requirements of uRLLCs. Approximated expressions of the average block error rate (BLER) are derived over Rayleigh fading channels, based on which a dataset is created for the training and testing of the DNN. For evaluating the improvement of the DNN, the root mean square error (RMSE) method is utilized. Simulation results show RMSE significantly decreases when a number of test samples increase.

Keywords: Deep learning, intelligent reflecting surface, Rayleigh fading, short packet communications.



Nguyễn Thị Yến Linh hiện đang là giảng viên thuộc Khoa Cơ Bản 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh, nhận bằng Thạc sĩ vào năm 2008 tại Trường Khoa Học Tự Nhiên TP. HCM. Hiện nay, ThS Linh đang là nghiên cứu sinh ngành kỹ thuật điện

thuật TP. Hồ Chí Minh (HCMUTE). Hướng nghiên cứu chính bao gồm: truyền thông hợp tác, thu thập năng lượng vô tuyến, truyền thông gói tin ngắn và deep learning.



Võ Nguyễn Quốc Bảo tốt nghiệp Tiến sĩ chuyên ngành vô tuyến tại Đại học Ulsan, Hàn Quốc vào năm 2010. Hiện nay, TS. Bảo là phó giáo sư của Bộ Môn Vô Tuyến, Khoa Viễn Thông 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh và đồng thời là giám đốc của phòng thí nghiệm nghiên cứu vô tuyến (WCOMM). TS.

Bảo hiện là thành viên chủ chốt (senior member) của IEEE và là tổng biên tập kỹ thuật của tạp chí REV Journal on Electronics and Communication. TS. Bảo đồng thời là biên tập viên (editor) của nhiều tạp chí khoa học chuyên ngành uy tín trong và ngoài nước, ví dụ: Transactions on Emerging Telecommunications Technologies (Wiley ETT), VNU Journal of Computer Science and Communication Engineering. TS. Bảo đã tham gia tổ chức nhiều hội nghị quốc gia và quốc tế, ví dụ: ATC (2013, 2014), NAFOSTED-NICS (2014, 2015, 2016), REV-ECIT 2015, ComManTel (2014, 2015) và SigComTel 2017. Hướng nghiên cứu hiện tại đang quan tâm bao gồm: vô tuyến nhận thức, truyền thông hợp tác, truyền song công, bảo mật lớp vật lý và thu thập năng lượng vô tuyến và deep learning.



Phạm Ngọc Sơn tốt nghiệp Tiến sĩ chuyên ngành điện tử viễn thông tại Đại học Ulsan, Hàn Quốc vào năm 2015. Hiện nay, TS. Sơn là giảng viên của Bộ Môn Kỹ Thuật Máy Tính Viễn Thông, Khoa Điện – Điện Tử, Trường Trường Đại học Sư Phạm Kỹ Thuật TP. Hồ Chí Minh (HCMUTE). Hướng nghiên cứu hiện tại đang quan tâm bao gồm: vô tuyến nhận thức, truyền thông hợp tác, truyền song công, bảo mật lớp vật lý, thu thập năng lượng vô tuyến, đa truy cập không trực giao, mặt phản xạ thông minh và truyền thông gói tin ngắn.

PHÂN TÍCH ĐỘ LỢI PHÂN TẬP CHO MẠNG CHUYỂN TIẾP QUA MẶT PHẢN XẠ THÔNG MINH VÀ NÚT CHUYỂN TIẾP TRONG TRUYỀN THÔNG GÓI TIN NGẮN

Nguyễn Thị Yến Linh*, Võ Nguyễn Quốc Bảo#, Phạm Ngọc Sơn⁺

*Khoa Cơ bản 2, Học Viện Công Nghệ Bưu Chính Viễn Thông

Khoa Viễn thông 2, Học Viện Công Nghệ Bưu Chính Viễn Thông

⁺ Trường Đại học Sư Phạm Kỹ Thuật Thành Phố Hồ Chí Minh

Tóm tắt- Mặt phản xạ thông minh (IRS) là một công nghệ mới, mang tính cách mạng và có thể cải thiện đáng kể hiệu năng của mạng truyền thông không dây thế hệ mới bằng cách điều khiển pha hoặc biên độ của tín hiệu trong môi trường vô tuyến thông qua các phản tử phản xạ thụ động. Trong bài báo này, chúng tôi đề xuất mô hình chuyển tiếp gói tin ngắn qua mặt phản xạ thông minh. Tiếp đến, chúng tôi so sánh độ lợi phân tập của hệ thống truyền tin này với hệ thống truyền tin qua nút chuyển tiếp cơ bản trong truyền thông gói tin ngắn. Trong đó, nút chuyển tiếp sử dụng kỹ thuật giải mã và chuyển tiếp cố định (FDF) để truyền dữ liệu. Để phân tích chất lượng mạng của hai hệ thống này, đầu tiên chúng tôi đưa ra các biểu thức dạng chính xác và xấp xỉ của tỉ lệ lỗi khối (BLER) qua kênh truyền fading Rayleigh. Tiếp đến dựa vào tỉ lệ lỗi khối BLER chúng tôi cũng rút ra được độ lợi phân tập của cả hai hệ thống. Qua đó, kết quả cho thấy hiệu năng của hệ thống truyền tin có sự hỗ trợ của mặt phản xạ thông minh IRS vượt trội hơn hệ thống truyền tin cơ bản qua nút chuyển tiếp FDF. Cuối cùng, chúng tôi chứng minh các kết quả trong phân tích lý thuyết hoàn toàn trùng khớp với kết quả mô phỏng bằng phương pháp mô phỏng Monte-Carlo.

Từ khóa- Mặt phản xạ thông minh, fading Rayleigh, giải mã và chuyển tiếp, tỉ lệ lỗi khối, truyền thông gói tin ngắn.

I. GIỚI THIỆU

Hệ thống truyền thông di động thế hệ mới trong tương lai (5G) sẽ tăng cường nhiều dịch vụ quan trọng, bao gồm giao tiếp kiểu máy (mMTC), băng thông rộng di động nâng cao (eMBB) và giao tiếp cực kỳ đáng tin cậy và độ trễ cực thấp (uRLLC) [1-4]. Dựa trên tiêu chuẩn công nghệ IMT-2020/5G của liên minh Viễn thông quốc tế (ITU-R), mạng 5G sẽ đáp ứng những yêu cầu nghiêm ngặt như tỉ lệ dữ liệu cao nhất 10-20Gbps; mật độ kết nối 10^6 thiết bị/km², xác suất lỗi dưới 10^{-5} và độ trễ dưới 1ms [2, 4]. Trong những yêu cầu này, hiện nay yêu cầu hệ thống về

độ trễ và độ tin cậy (uRLLC) được quan tâm nhất. Do vậy, truyền thông gói tin ngắn ra đời đáp ứng hoàn toàn yêu cầu về uRLLC trong hệ thống mạng 5G và cả các hệ thống mạng thế hệ tương lai tiếp theo ví dụ như 5.5G và 6G [5].

Cho đến nay, mạng 5G đã được tích hợp nhiều kỹ thuật tiên tiến để nâng cao độ tin cậy cũng như hiệu năng hệ thống mạng ví dụ như: đa truy nhập không trực giao (NOMA), kỹ thuật chuyển tiếp, công nghệ vô tuyến nhận thức (CR). Trong đó, mạng chuyển tiếp được xem là kỹ thuật hiệu quả để mở rộng vùng phủ sóng và nâng cao hiệu năng của mạng [6, 7]. Ý tưởng chính của mạng chuyển tiếp là cải thiện hiệu năng truyền tải dữ liệu hiệu quả bằng cách sử dụng các nút chuyển tiếp trung gian để hỗ trợ truyền dữ liệu từ nguồn đến đích. Về cơ bản, nút trung gian sử dụng hai kỹ thuật để xử lý và chuyển tiếp tín hiệu đến đích, đó là kỹ thuật khuếch đại và chuyển tiếp (AF) [8, 9] và giải mã và chuyển tiếp (DF) [10, 11].

Gần đây, các nhà khoa học đã bắt đầu quan tâm đến việc ứng dụng mạng chuyển tiếp vào truyền thông gói tin ngắn nhằm đáp ứng yêu cầu về độ tin cậy cực cao trong mạng 5G. Cụ thể, các tác giả trong bài báo [12] đã chứng minh sự vượt trội về hiệu năng và độ trễ giảm của hệ thống mạng hai chiều khuếch đại và chuyển tiếp AF trong truyền thông gói tin ngắn, hay ở bài báo [13] các tác giả nghiên cứu kỹ thuật lựa chọn nút chuyển tiếp từng phần trong mạng chuyển tiếp hai chặng DF và bài báo cho thấy được sự cải thiện hiệu năng hệ thống thông qua truyền gói tin ngắn. Tương tự, tác giả trong bài báo [14] cũng cho thấy sự giảm hẳn của tỉ lệ lỗi khối và độ trễ trong mạng chuyển tiếp hai chặng DF thu thập năng lượng thông qua truyền gói tin ngắn.

Mặc dù, mạng chuyển tiếp có nhiều cải tiến về hiệu năng cũng như hiệu quả phổ, nhưng trong quá trình thực thi hệ thống khá phức tạp và năng lượng tiêu thụ của nguồn phát quá lớn. Chính vì vậy, hiện nay mặt phản xạ thông minh (IRS) là một trong những giải pháp tối ưu để giảm thiểu tiêu thụ điện năng truyền dẫn, đồng thời tăng hiệu quả sử dụng phổ trong quá trình thiết kế hệ thống mạng [15]. IRS là một mảng bao gồm một số lượng lớn các phản tử phản xạ chi phí thấp, có khả năng phản xạ các tín hiệu tới bằng cách điều chỉnh sự dịch chuyển pha [16]. Về cơ bản, mặt phản xạ thông minh IRS có chức năng tương tự nút chuyển tiếp trong mạng chuyển tiếp, đó là hỗ trợ truyền tải dữ liệu từ nguồn đến đích bằng cách điều khiển IRS để phát tia tín hiệu nhận được từ nguồn đến đích.

Tác giả liên hệ: Nguyễn Thị Yến Linh,

Email: yenlinh@ptithcm.edu.vn

Đến tòa soạn: 22/9/2021, chỉnh sửa: 10/12/2021, chấp nhận đăng: 17/12/2021.


Hơn nữa, một số nghiên cứu gần đây cho thấy truyền dẫn thông tin qua mặt phản xạ thông minh IRS vượt trội hơn hẳn về hiệu năng hệ thống [17, 18] và giảm hơn công suất phát của nguồn phát so với truyền dẫn thông tin qua nút chuyển tiếp [15]. Tuy nhiên, các nghiên cứu này chủ yếu tập trung so sánh giữa truyền thông tin gói tin dài qua mặt phản xạ IRS và qua nút chuyển tiếp. Theo sự hiểu biết của chúng tôi, hiện nay chưa có công trình nghiên cứu nào quan tâm đến truyền dẫn thông tin gói tin ngắn qua mặt phản xạ thông minh IRS, cũng như so sánh hiệu năng giữa hai mô hình truyền dẫn này. Do vậy, nhằm đáp ứng yêu cầu uRLLC trong mạng thế hệ mới tương lai bài báo đề xuất mô hình truyền dẫn thông tin gói ngắn qua mặt IRS và qua nút giả mã và chuyển tiếp cố định (FDF). Tiếp đến, để so sánh hiệu năng của hai mô hình này chúng tôi đưa ra các biểu thức dạng chính xác và xấp xỉ của tỉ lệ lỗi khối (BLER) thông qua kênh fading Rayleigh. Cuối cùng, mô phỏng Monte-Carlo được thực hiện để kiểm chứng các kết quả lý thuyết của hai mô hình hệ thống mà chúng tôi đề xuất.

Phần còn lại của bài báo được trình bày như sau. Phần II sẽ trình bày mô hình của hệ thống mạng chuyển tiếp qua mặt IRS và mô hình chuyển tiếp FDF hai chặng. Phương pháp phân tích theo hai mô hình đề xuất qua tỉ lệ lỗi khối với cả hai dạng chính xác và xấp xỉ sẽ được chứng minh trong Phần III. Phần IV, chúng tôi sẽ tiến hành mô phỏng Monte-Carlo để kiểm chứng lại các kết quả lý thuyết trong Phần III. Cuối cùng là phần kết luận của bài báo.

II. MÔ HÌNH HỆ THỐNG

Trong phần này, chúng tôi trình bày hai mô hình hệ thống bao gồm mô hình đề xuất sử dụng IRS và mô hình truyền thông qua FDF.

A. CHUYỂN TIẾP QUA IRS



Hình 1 Mô hình truyền gói tin ngắn qua mặt phản xạ thông minh.

Mô hình hệ thống truyền gói tin ngắn qua IRS được mô tả qua Hình 1. Hệ thống bao gồm một trạm BS (Base Station), đóng vai trò nguồn phát sóng (S), nguồn nhận (D) và một IRS bao gồm N tấm mặt phản xạ thụ động (MS). Trong đó, nguồn S và đích D được trang bị một ăng ten. Giả sử rằng không có đường truyền trực tiếp giữa nguồn và đích do vật cản từ môi trường. Hơn nữa, chúng tôi xét IRS hoạt động như một bộ phản xạ thông minh. Tức là IRS có thể phối hợp, trao đổi thông tin trạng thái kênh từ nguồn và đích thông qua liên kết không dây, từ đó có

thể điều chỉnh pha của tất cả phần tử phản xạ sao cho tỉ số tín hiệu trên nhiễu nhận tại đích đạt lớn nhất [16]. Mặt khác, do suy hao tín hiệu đáng kể nên chúng tôi chỉ xét tín hiệu phản xạ trên IRS một lần và bỏ qua tín hiệu phản xạ hai lần trở lên [19]. Giả sử rằng kênh truyền giữa nguồn và đích là kênh Rayleigh fading bán tĩnh phẳng.

Tín hiệu nhận tại đích D được biểu diễn như sau:

$$y_D = \sqrt{P} \left[\sum_{i=1}^N h_i r_i g_i \right] x_D + n_D, \quad (1)$$

với P là công suất phát của nguồn S , x_D là tín hiệu cần truyền đến đích D , n_D là nhiễu Gauss trắng cộng (AWGN) với trung bình 0 và phương sai N_0 . Hơn nữa, r_i là hệ số phản xạ được tạo ra bởi yếu tố phản xạ thứ i trong IRS ($i = 1, 2, \dots, N$) [17].

$$r_i = |r_i| e^{j\phi_i}, \quad (2)$$

với biên độ phản xạ $|r_i| = 1$ cho độ dịch pha lý tưởng và ϕ_i là độ dịch chuyển pha của yếu tố phản xạ thứ i trong IRS. Kế tiếp, h_i và g_i là hệ số kênh truyền từ nguồn S đến yếu tố phản xạ thứ i trong IRS và từ yếu tố phản xạ thứ i đến đích D , tương ứng.

$$h_i = d_1^{-\nu/2} \alpha_i e^{-j\theta_i}, \quad (3)$$

$$g_i = d_2^{-\nu/2} \beta_i e^{-j\phi_i}, \quad (4)$$

với α_i, β_i và θ_i, ϕ_i lần lượt là biên độ và độ dịch pha của hệ số kênh h_i và g_i ; d_1 và d_2 lần lượt là khoảng cách từ nguồn S đến IRS và từ IRS đến đích D tương ứng; ν là hệ số suy hao đường truyền. Mô hình suy hao đường truyền trong hệ thống giao tiếp này, chúng tôi xét trường gần, tức khoảng cách giữa nguồn hoặc đích đến chính giữa IRS nhỏ hơn $\frac{2D^2}{\lambda}$, với D kích thước cực đại của IRS và λ là bước sóng của tín hiệu truyền [20].

Từ (1), tỉ số tín hiệu trên nhiễu (SNR) tức thời thu được tại đích D được xác định như sau

$$\gamma_D = \frac{P \left| \sum_{i=1}^N \alpha_i \beta_i e^{j(\phi_i - \theta_i - \phi_i)} \right|^2}{d_1^\nu d_2^\nu N_0}. \quad (5)$$

Để SNR trong (5) đạt giá trị lớn nhất, IRS chọn góc dịch chuyển pha $\phi_i = \theta_i + \phi_i$ [20]. Hơn nữa, đặt $A = \sum_{i=1}^N \frac{\alpha_i \beta_i}{d_1^\nu d_2^\nu}$, (5) có thể viết lại như sau

$$\gamma_D = A^2 \bar{\gamma}, \quad (6)$$

với $\bar{\gamma} = \frac{P}{N_0}$ là SNR trung bình.

Như đã được chứng minh trong [17, Định lý 1], với α_i và β_i là những biến ngẫu nhiên độc lập, theo phân bố

Rayleigh có trung bình $\frac{\sqrt{\pi}}{2}$ và phương sai $\frac{4-\pi}{4}$, nên theo định lý giới hạn trung tâm A tuân theo phân bố Gauss khi N đủ lớn [21]. Nên từ (6), hàm mật độ xác suất (PDF) và hàm phân phối tích lũy (CDF) của γ có dạng như sau [17]

$$f_{\gamma}(\gamma) = \frac{1}{2b^{a+1}\Gamma(a+1)\bar{\gamma}^{\frac{a+1}{2}}} \gamma^{\left(\frac{a-1}{2}\right)} \exp\left(\frac{1}{b}\sqrt{\gamma/\bar{\gamma}}\right), \quad (7)$$

và

$$F_{\gamma}(\gamma) = \frac{\Upsilon\left(a+1, \frac{1}{b}\sqrt{\frac{\gamma}{\bar{\gamma}}}\right)}{\Gamma(a+1)} \quad (8)$$

$$\stackrel{(i)}{=} 1 - \frac{\Gamma\left(a+1, \frac{1}{b}\sqrt{\frac{\gamma}{\bar{\gamma}}}\right)}{\Gamma(a+1)},$$

với (i) là phép rút gọn sử dụng [22, CT(8356.3)]; hàm gamma không hoàn chỉnh cận trên được định nghĩa như sau [22, CT(8.310.1)]

$$\Gamma(\alpha, x) = \int_x^{\infty} e^{-t} t^{\alpha-1} dt. \quad (9)$$

và

$$a = \frac{k_1^2}{k_2} - 1, \quad (10)$$


$$b = \frac{k_2}{k_1}, \quad (11)$$

$$k_1 = \frac{N\pi}{4} \sqrt{\frac{1}{d_1^v d_2^v}}, \quad (12)$$

$$k_2 = \frac{N}{d_1^v d_2^v} \left(1 - \frac{\pi^2}{16}\right). \quad (13)$$

Chứng minh: công thức (12) và (13) như trong phần phụ lục.

B. CHUYỂN TIẾP QUA NÚT CHUYỂN TIẾP



Hình 2. Mô hình truyền gói tin ngắn qua nút chuyển tiếp FDF.

Mô hình hệ thống truyền tin qua nút chuyển tiếp FDF được mô tả qua Hình 2. Ở mô hình này, chúng tôi xét tương tự như mô hình hệ thống truyền tin qua IRS về giả định và cấu trúc của mô hình bằng cách thay IRS bằng nút chuyển tiếp (R). Tuy nhiên, quá trình truyền tin từ nút nguồn và nút đích được thực hiện trong hai khe thời gian liên tiếp thông qua sự trợ giúp của nút chuyển tiếp. Trong

khe thời gian đầu tiên, nút nguồn sẽ truyền tín hiệu tới nút chuyển tiếp và nút chuyển tiếp chuyển tiếp tín hiệu nhận được đến đích bằng kỹ thuật giải mã chuyển tiếp cố định FDF. Như đã được dẫn ra trong [23], tỉ số tín hiệu trên nhiễu (SNR) toàn trình của hệ thống như sau:

$$\gamma_{DF} = \min(\gamma_{SR}, \gamma_{RD}), \quad (14)$$

với γ_{SR} và γ_{RD} là tỉ số tín hiệu trên nhiễu SNR từ $S \rightarrow R$ và $R \rightarrow D$, tương ứng.

Giả định các kênh truyền từ $S \rightarrow R$ và $R \rightarrow D$ là các kênh truyền fading Rayleigh độc lập và có phân bố giống nhau (i.i.d.), tức hệ số kênh của các kênh truyền này được xem như là các biến ngẫu nhiên độc lập và có phân bố giống nhau. Cũng theo [23], hàm phân phối tích lũy CDF của γ_{DF} có thể được đưa ra như sau

$$F_{\gamma_{DF}}(\gamma) = \Pr(\gamma_{DF} \leq \gamma) = 1 - \exp\left(-\left(\frac{\gamma}{\bar{\gamma}_{SR}} + \frac{\gamma}{\bar{\gamma}_{RD}}\right)\right), \quad (15)$$

với $\bar{\gamma}_{SR}$ và $\bar{\gamma}_{RD}$ là tỷ lệ tín hiệu trên nhiễu trung bình lần lượt của chặng $S \rightarrow R$ và $R \rightarrow D$.

III. ĐÁNH GIÁ HIỆU NĂNG HỆ THỐNG

Trong phần này, chúng tôi sử dụng thông số tỉ lệ lỗi khối để đánh giá hiệu năng của hệ thống truyền tin qua IRS và nút chuyển tiếp FDF.

A. TỈ LỆ LỖI KHỐI DẠNG CHÍNH XÁC

Chúng tôi giả sử rằng nguồn S truyền β bit thông tin đến đích D trên k kênh sử dụng (chiều dài khối tin) trong một chu kỳ truyền qua kênh fading bán tĩnh [24]. Tốc độ mã hóa của mỗi chu kỳ truyền được xác định là

$$R = \frac{\beta}{k}. \quad (16)$$

Như đã được nghiên cứu trong truyền thông gói tin ngắn [25], chiều dài khối tin yêu cầu ở mức tối thiểu $k \geq 100$ và tốc độ mã hóa tối đa tương ứng được xấp xỉ như sau

$$R \approx C(\gamma_x) - \sqrt{V(\gamma_x)/k} Q^{-1}(\varepsilon_x), \quad (17)$$

với ε_x là tỉ lệ lỗi khối BLER tức thời ở chặng thứ X , $C(\gamma_x) = \log_2(1 + \gamma_x)$ là dung lượng kênh Shannon, $V(\gamma_x) = \left(1 - \frac{1}{(1 + \gamma_x)^2}\right)(\log_2 e)^2$ là độ phân tán kênh truyền [5] và $Q^{-1}(\cdot)$ là nghịch của hàm Q-function với

$$Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^{\infty} \exp\left(-\frac{t^2}{2}\right) dt \quad [26].$$

Từ (17) tỉ lệ lỗi khối trung bình BLER ở mỗi chặng có thể được xấp xỉ như trong [27, CT(59)] và [28, CT(4)] như sau

$$\bar{\varepsilon}_x \approx E_{\gamma_x} \left\{ Q \left(\frac{C(\gamma_x) - R}{\sqrt{V(\gamma_x)/k}} \right) \right\}, \quad (18)$$

với $E\{\cdot\}$ là toán tử kỳ vọng.

Từ (18), tỉ lệ lỗi khối trung bình BLER có thể được viết lại như sau

$$\bar{\varepsilon}_x \approx \int_0^\infty Q \left(\frac{C(\gamma_x) - R}{\sqrt{V(\gamma_x)/k}} \right) f_{\gamma_x}(\gamma) d\gamma, \quad (19)$$

với $f_{\gamma_x}(\gamma)$ là hàm mật độ phân phối của γ_x .

Để tính tích phân trong (19) đơn giản hơn, chúng tôi sử dụng xấp xỉ của hàm $Q(\cdot)$ trong [25, CT(14)], cụ thể

$$\text{là } Q \left(\frac{C(\gamma_x) - R}{\sqrt{V(\gamma_x)/k}} \right) \approx \Psi(\gamma_x), \text{ với}$$

$$\Psi(\gamma_x) = \begin{cases} 1, & \gamma_x \leq \rho_L \\ 0.5 - v\sqrt{k}(\gamma - \theta), & \rho_L < \gamma_x < \rho_H \\ 0, & \gamma_x \geq \rho_H \end{cases}, \quad (20)$$

$$\text{với } v = \frac{1}{2\pi\sqrt{2^r - 1}}, \quad \theta = 2^r - 1, \quad \rho_H = \theta + \frac{1}{2v\sqrt{k}} \text{ và}$$

$$\rho_L = \theta - \frac{1}{2v\sqrt{k}}.$$

Bằng cách thay (20) vào (19) và thực hiện phép lấy tích phân từng phần, tỉ lệ lỗi khối trung bình BLER thu được như sau

$$\bar{\varepsilon}_x = v\sqrt{k} \int_{\rho_L}^{\rho_H} F_{\gamma_x}(\gamma) d\gamma. \quad (21)$$

1) CHUYỂN TIẾP QUA IRS

Thay (8) vào (21), tỉ lệ lỗi khối toàn trình của hệ thống chuyển tiếp qua IRS thu được như sau

$$\bar{\varepsilon}_{e2e}^{IRS} = v\sqrt{k} \int_{\rho_L}^{\rho_H} F_\gamma(\gamma) d\gamma,$$

$$= v\sqrt{k}(\rho_H - \rho_L) - v\sqrt{k} \int_{\rho_L}^{\rho_H} \frac{\Gamma\left(a+1, \frac{1}{b}\sqrt{\frac{\gamma}{\bar{\gamma}}}\right)}{\Gamma(a+1)} d\gamma,$$

$$\stackrel{(ii)}{=} v\sqrt{k} \left[\rho_H - \rho_L - \frac{2}{\Gamma(a+1)} \left(\Delta(\sqrt{\rho_H}) - \Delta(\sqrt{\rho_L}) \right) \right], \quad (22)$$

với (ii) là phép lấy tích phân theo γ , hàm $\Delta(\gamma)$ được đặt như sau

$$\Delta(\gamma) = \frac{1}{2} \left[\gamma^2 \Gamma\left(a+1, \frac{\gamma}{b\sqrt{\bar{\gamma}}}\right) - \frac{\gamma^{a+2}}{(b\sqrt{\bar{\gamma}})^a} e^{-\frac{\gamma}{b\sqrt{\bar{\gamma}}}} \right. \\ \left. - \frac{(a+2)}{\left(\frac{1}{b\sqrt{\bar{\gamma}}}\right)^2} \Gamma\left(a+2, \frac{\gamma}{b\sqrt{\bar{\gamma}}}\right) \right]. \quad (23)$$

2) CHUYỂN TIẾP QUA NÚT CHUYỂN TIẾP

Thay (15) vào (21), tỉ lệ lỗi khối toàn trình của hệ thống chuyển tiếp qua nút chuyển tiếp thu được như sau

$$\bar{\varepsilon}_{e2e}^{FDF} = v\sqrt{k} \left\{ (\rho_H - \rho_L) + \left(\frac{\bar{\gamma}_{SR}\bar{\gamma}_{RD}}{\bar{\gamma}_{SR} + \bar{\gamma}_{RD}} \right) \right. \\ \left. \times \exp \left[- \left(\frac{\gamma}{\bar{\gamma}_{SR}} + \frac{\gamma}{\bar{\gamma}_{RD}} \right) \right] \right\}. \quad (24)$$

B. TỈ LỆ LỖI KHỐI DẠNG XẤP XỈ

Tiếp theo, chúng tôi sẽ trình bày dạng xấp xỉ của tỉ lệ lỗi khối để có đánh giá khách quan hơn về hiệu năng của hệ thống khi chuyển tiếp qua IRS và qua nút chuyển tiếp ở mức SNR trung bình $\bar{\gamma}$ cao. Dạng xấp xỉ này được xem như là một đường giới hạn trên cho các giá trị của tỉ lệ lỗi khối khi càng tăng SNR trung bình tiến ra vô cùng. Điều này có nghĩa là tỉ lệ lỗi khối toàn trình của hệ thống luôn đạt giá trị nhỏ hơn hoặc bằng giá trị đường giới hạn trên cho dù có tăng SNR trung bình thế nào đi chăng nữa. Mặt khác, đây cũng là điều mà ta mong muốn vì tỉ lệ lỗi khối càng nhỏ thì hiệu năng hệ thống càng được cải thiện.

1) CHUYỂN TIẾP QUA IRS

Áp dụng công thức [22, CT(8354.1)], (8) được viết lại như sau

$$F_\gamma(\gamma) \approx \frac{1}{\Gamma(a+1)} \sum_{m=0}^{\infty} \frac{(-1)^m \left(\frac{1}{b}\sqrt{\frac{\gamma}{\bar{\gamma}}} \right)^{a+1+m}}{m!(a+1+m)}, \quad (25)$$

với m là số bậc khai triển.

Thay (25) vào (21), dạng xấp xỉ tỉ lệ lỗi khối toàn trình của hệ thống chuyển tiếp qua IRS có thể tính được như sau

$$\bar{\varepsilon}_{e2e}^{IRS} \approx \frac{v\sqrt{k}}{\Gamma(a+1)} \sum_{m=0}^{\infty} \frac{(-1)^m}{m!(a+1+m)(a+2+m)} \\ \times \left[\left(\frac{1}{b}\sqrt{\frac{\rho_H}{\bar{\gamma}}} \right)^{a+2+m} - \left(\frac{1}{b}\sqrt{\frac{\rho_L}{\bar{\gamma}}} \right)^{a+2+m} \right]. \quad (26)$$

Ngoài ra, khi SNR trung bình $\bar{\gamma} \rightarrow \infty$ độ lợi phân tập của hệ thống trong trường hợp chuyển tiếp qua IRS được tính như sau [17, Lý thuyết 5]

$$D^{IRS} = -\lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \bar{\varepsilon}_{e2e}^{IRS}}{\log \bar{\gamma}}. \quad (27)$$

Bằng cách đặt

$$Z_1 = \frac{v\sqrt{k}}{\Gamma(a+1)} \frac{(-1)^m}{m!(a+1+m)(a+2+m)}. \quad (28)$$

$$Z_2 = \left(\frac{1}{b}\sqrt{\rho_H}\right)^{a+2+m} - \left(\frac{1}{b}\sqrt{\rho_L}\right)^{a+2+m}. \quad (29)$$

Thay thế (28) và (29) vào (26), độ lợi D^{IRS} thu được như sau

$$\begin{aligned} D^{IRS} &= -\lim_{\bar{\gamma} \rightarrow \infty} \left[\frac{\log\left(\sum_{m=0}^{\infty} Z_1\right) + \log\left(\sum_{m=0}^{\infty} Z_2\right)}{\log(\bar{\gamma})} \right. \\ &\quad \left. + \frac{\log\left(\sum_{m=0}^{\infty} \bar{\gamma}^{-\frac{a+2+m}{2}}\right)}{\log(\bar{\gamma})} \right] \\ &= -\lim_{\bar{\gamma} \rightarrow \infty} \frac{\log\left(\sum_{m=0}^{\infty} \bar{\gamma}^{-\frac{a+2+m}{2}}\right)}{\log(\bar{\gamma})}. \end{aligned} \quad (30)$$

Bằng cách tính tổng như sau

$$\sum_{m=0}^{\infty} \bar{\gamma}^{-\frac{a+2+m}{2}} = \frac{\bar{\gamma}^{-\frac{a+1}{2}}}{\bar{\gamma}^{\frac{1}{2}} - 1}. \quad (31)$$

Thay (31) vào (30) và ta viết lại (30) như sau

$$\begin{aligned} D^{IRS} &= -\lim_{\bar{\gamma} \rightarrow \infty} \left[\frac{\log\left(\bar{\gamma}^{-\frac{a+1}{2}}\right)}{\log(\bar{\gamma})} - \frac{\log\left(\bar{\gamma}^{\frac{1}{2}}\right)}{\log(\bar{\gamma})\log 1} \right] \\ &= \frac{a+1}{2}. \end{aligned} \quad (32)$$

Thay thế (12) và (13) vào (10), giá trị a trong (32) có giá trị như sau

$$a = \frac{N\pi^2}{16 - \pi^2} - 1. \quad (33)$$

Từ (33) và (32) ta dễ dàng thấy rằng a phụ thuộc vào số yếu tố phân xạ N , tức khi tăng giá trị N thì a cũng tăng. Trong IRS, giá trị N luôn lớn hơn 1 ($N > 1$) nên giá trị $a > 2$. Do đó, độ lợi phân tập của hệ thống chuyển tiếp qua IRS $D^{IRS} > 1$.

2) CHUYỂN TIẾP QUA NÚT CHUYỂN TIẾP

Áp dụng công thức xấp xỉ $1 - \exp(-x) \approx x$ khi $x \rightarrow 0$ cho (24), dạng xấp xỉ tỉ lệ lỗi khối toàn trình của hệ thống chuyển tiếp qua nút chuyển tiếp thu được như sau

$$\bar{\varepsilon}_{e2e}^{FDF} \approx \frac{v\sqrt{k}}{2} \left(\frac{\bar{\gamma}_{SR} + \bar{\gamma}_{RD}}{\bar{\gamma}_{SR} \bar{\gamma}_{RD}} \right) (\rho_H^2 - \rho_L^2). \quad (34)$$

Tương tự (27), độ lợi phân tập của hệ thống chuyển tiếp qua nút chuyển tiếp thu được như sau

$$D^{FDF} = -\lim_{\bar{\gamma} \rightarrow \infty} \frac{\log \bar{\varepsilon}_{e2e}^{FDF}}{\log \bar{\gamma}}. \quad (35)$$

Thay (24) vào (35) và thực hiện một số phép biến đổi rút gọn, ta được độ lợi như sau

$$\begin{aligned} D^{FDF} &= -\lim_{\bar{\gamma} \rightarrow \infty} \left[\frac{\log\left(\frac{v\sqrt{k}}{2}(\rho_H^2 - \rho_L^2)\right)}{\log(\bar{\gamma})} \right. \\ &\quad \left. + \frac{\log\left(\frac{2}{h_r^2 g_r^2}(h_r^2 + g_r^2/2)\right)}{\log(\bar{\gamma})} + \frac{\log \bar{\gamma}^{-1}}{\log(\bar{\gamma})} \right] \\ &= 1. \end{aligned} \quad (36)$$

Từ (36) và (32) chứng tỏ rằng $D^{IRS} > D^{FDF}$, hay nói khác hơn truyền dẫn thông tin qua IRS đạt độ phân tập cao hơn chuyển tiếp qua FDF, tức hệ thống đạt độ tin cậy cao hơn hệ thống chuyển tiếp qua nút chuyển tiếp FDF. Hơn nữa, càng tăng N thì hiệu năng của hệ thống chuyển tiếp qua IRS càng cải thiện do độ lợi phân tập tăng tỉ lệ theo số yếu tố phân xạ N .

IV. KẾT QUẢ MÔ PHỎNG VÀ THẢO LUẬN

Trong phần này, chúng tôi sử dụng phương pháp mô phỏng Monte-Carlo trên phần mềm Matlab cho mô hình đề xuất để kiểm chứng lại các kết quả lý thuyết đã được trình bày ở Phần III [29]. Đặc biệt, chúng tôi sẽ thảo luận về các đặc điểm hiệu năng hệ thống cũng như các thông số thiết kế hệ thống tối ưu cho mô hình mà chúng tôi đề xuất.

Các thông số được chúng tôi sử dụng để thực hiện mô phỏng như số bit thông tin là $\beta = 256$ bit và chiều dài khối $k = 200$. Để việc tính toán đơn giản chúng tôi giả định rằng tổng khoảng cách truyền được chuẩn hóa với $D=1$. Với giả định phân bố vị trí đặt trạm IRS và nút chuyển tiếp ở ngay chính giữa nút nguồn và nút đích, khoảng cách đường truyền từ $S \rightarrow IRS$ và $IRS \rightarrow D$ là

$d_1 = d_2 = \frac{D}{2}$. Tương tự cho trường hợp chuyển tiếp qua

nút chuyển tiếp FDF, d_1 và d_2 lần lượt khoảng cách đường truyền từ $S \rightarrow R$ và $R \rightarrow D$. Hơn nữa, để so sánh công bằng chúng tôi giả sử rằng tổng công suất truyền của cả hai mô hình chuyển tiếp qua IRS và qua FDF là như nhau và xem xét mô hình suy hao đường truyền đơn giản với hệ số suy hao đường truyền là 2 [30]. Mặt khác,


chúng tôi gọi $\bar{\gamma} = \frac{P}{N_0}$ là SNR trung bình của nguồn phân

bổ năng lượng với P là tổng năng lượng được phân bổ. Do N_0 là hằng số nên ta có thể hiểu rằng khi tăng SNR cũng có nghĩa là tăng công suất phát của nguồn cung cấp năng lượng.

Đầu tiên, chúng tôi so sánh tỉ lệ lỗi khối BLER toàn trình trong hai trường hợp chuyển tiếp gói tin ngắn qua IRS và qua nút chuyển tiếp cố định FDF. Tỉ lệ lỗi khối BLER là một hàm của SNR trung bình $\bar{\gamma}$ với giả sử cố định số yếu tố phản xạ trong IRS với $N = 3$ như trong Hình 3.


Quan sát Hình 3, ta dễ dàng thấy rằng kết quả mô phỏng hoàn toàn trùng khớp với kết quả lý thuyết và kết quả đường xấp xỉ hội tụ với các đường lý thuyết ở SNR cao. Điều này chứng minh các kết quả phân tích lý thuyết của chúng tôi trong phần III hoàn toàn chính xác. Hơn nữa, ta có thể thấy rõ ở mô hình chuyển tiếp qua IRS tỉ lệ lỗi khối BLER giảm nhanh ở giá trị $\bar{\gamma}$ âm (10^{-5}), càng tăng $\bar{\gamma}$ thì tỉ số lỗi giảm chậm dần điều này hoàn toàn phù hợp với kết quả lý thuyết trong (22). Bởi vì BLER tỉ lệ với $\exp\left(-\frac{\gamma}{\bar{\gamma}}\right)$, đây là một hàm giảm với mọi giá trị của $\bar{\gamma}$ tức với mọi giá trị của công suất phát của nguồn. Đặc biệt càng giảm nhanh ở những giá trị âm càng nhỏ.

Tuy nhiên, ở mô hình chuyển tiếp qua FDF, tỉ lệ lỗi khối BLER chỉ giảm dần ở khi giá trị dương $\bar{\gamma}$ tăng. Kết quả này phù hợp với kết quả lý thuyết vì BLER trong trường hợp này tỉ lệ với $\bar{\gamma} \exp\left(-\frac{\gamma}{\bar{\gamma}}\right)$ trong (24). Do đó, BLER chỉ chọn các giá trị dương $\bar{\gamma}$ như trong Hình 3. Từ Hình 3, ta cũng thấy được hiệu năng hệ thống của mô hình chuyển tiếp qua IRS (BLER giảm nhanh hơn) vượt trội hơn hẳn so với hiệu năng mô hình chuyển tiếp qua FDF. Trong truyền thông gói tin ngắn, có sự đánh đổi rất lớn giữa độ trễ và BLER. Tức với chiều dài gói tin như nhau, hệ thống có BLER lớn hơn thì độ trễ sẽ nhỏ hơn [31]. Tuy vậy, trong hệ thống chuyển tiếp gói tin ngắn có sự hỗ trợ của IRS, có hay không sự đánh đổi giữa độ trễ và BLER vẫn đang là một thử thách lớn đối với các nhà nghiên cứu hiện nay



Hình 3. So sánh BLER giữa hai mô hình chuyển tiếp qua IRS và qua FDF.


Tiếp theo, chúng tôi xét sự ảnh hưởng của yếu tố phản xạ N lên hiệu năng hệ thống của mô hình chuyển tiếp qua IRS trong ba trường hợp cụ thể của $\bar{\gamma}$ là $\bar{\gamma} = -30$, $\bar{\gamma} = -25$ và $\bar{\gamma} = -20$ như trong Hình 4.




Hình 4. Ảnh hưởng của số yếu tố phản xạ N lên BLER của mô hình chuyển tiếp qua IRS.

Trong Hình 4, ta cũng thấy rõ khi càng tăng N và $\bar{\gamma}$ thì BLER hệ thống càng giảm nhanh. Tuy nhiên, càng tăng $\bar{\gamma}$, tức tăng công suất phát quá lớn sẽ có thể dẫn đến can nhiễu lớn. Do đó, để cải thiện hiệu năng hệ thống với nguồn công suất phát cố định, ta có thể tăng số lượng số yếu tố phản xạ N sao cho tỉ số lỗi BLER giảm như ta mong đợi.

Cuối cùng, ta xét sự ảnh hưởng chiều dài gói tin lên hiệu năng hệ thống cả hai mô hình truyền tin qua IRS với các giá trị SNR $\bar{\gamma}$ tăng lần lượt -20dB , -15dB , -10dB như Hình 5 và truyền tin qua FDF với giá trị SNR $\bar{\gamma}$ lần lượt 10dB , 15dB và 20dB như Hình 6. Trong cả hai mô hình truyền tin qua IRS và FDF, ta thấy rằng khi k và $\bar{\gamma}$ tăng thì BLER giảm, đặc biệt BLER giảm nhanh hơn ở mô hình truyền tin qua IRS. Tuy nhiên, ta phải cân nhắc đến việc tăng $\bar{\gamma}$ (tức tăng công suất phát) vì can nhiễu lớn sẽ ảnh hưởng đến người dùng khác xung quanh. Mặt khác, nếu tăng giá trị chiều dài gói tin k thì sẽ dẫn đến độ trễ cũng tăng. Do vậy, tùy từng dịch vụ cụ thể ta sẽ chọn giá trị k và công suất phát tương ứng sao cho đáp ứng mục tiêu uRLLC trong mạng 5G.



Hình 5. Sự ảnh hưởng của chiều dài gói tin lên BLER chuyển tiếp qua IRS.



Hình 6. Sự ảnh hưởng của chiều dài gói tin lên BLER chuyển tiếp qua nút chuyển tiếp FDF.

V. KẾT LUẬN

Trong bài báo này, chúng tôi đã đề xuất mô hình truyền dẫn thông tin qua IRS trong truyền thông gói tin ngắn. Tiếp đến, chúng tôi so sánh hiệu năng của mô hình này với mô hình truyền gói tin ngắn qua nút chuyển tiếp FDF thông qua thông số tỉ lệ lỗi khối BLER và độ lợi phân tập. Dựa vào kết quả lý thuyết và được kiểm chứng một lần nữa qua mô phỏng Monte-Carlo, bài báo cho thấy rằng tỉ lệ lỗi khối BLER của hệ thống truyền tin qua IRS giảm nhanh so với tỉ số BLER trong truyền tin qua FDF thông thường và độ lợi phân tập mô hình truyền tin qua IRS cũng cao hơn mô hình truyền tin qua FDF. Hay nói khác hơn, hiệu năng của hệ thống mô hình truyền tin qua IRS cải thiện hơn mô hình truyền tin qua FDF. Hơn nữa, đối với hệ thống truyền tin qua IRS càng tăng số yếu tố phản xạ và công suất phát thì tỉ số lỗi càng giảm, hiệu năng càng cải thiện. Tuy nhiên, chiều dài gói tin cũng ảnh hưởng đáng kể đến hiệu năng hệ thống và tùy vào yêu cầu dịch vụ cụ thể thì ta sẽ xác định giá trị k cụ thể tương ứng sao cho đáp ứng yêu cầu uRLLC.

PHỤ LỤC

CHỨNG MINH CÔNG THỨC (12) VÀ (13)

$$\text{Từ công thức} \quad A = \sum_{i=1}^N \frac{\alpha_i \beta_i}{d_1^v d_2^v}. \quad (\text{P.1})$$

Bởi vì α_i và β_i là các biến ngẫu nhiên phân bố Rayleigh độc lập, do đó A là tổng của N quá trình double Rayleigh đồng dạng và độc lập. Theo phân tích trong [32, CT(2.76)], hàm PDF của A có dạng như (7). Trong đó, các tham số a và b được cho như trong công thức (10) và (11). Hơn nữa theo [32, CT(2.74)], k_1 và k_2 được định nghĩa là giá trị kỳ vọng và phương sai của A như sau

$$k_1 = E[A]. \quad (\text{P.2})$$

$$k_2 = V[A]. \quad (\text{P.3})$$

Thế (P.1) lần lượt vào (P.2) và (P.3), k_1 và k_2 thu được kết quả như sau

$$\begin{aligned} k_1 &= E \left[\sum_{i=1}^N \frac{\alpha_i \beta_i}{d_1^v d_2^v} \right] \\ &\stackrel{(a)}{=} \sum_{i=1}^N E \left[\frac{\alpha_i}{d_1^v} \right] E \left[\frac{\beta_i}{d_2^v} \right] \\ &= \frac{N\pi}{4} \sqrt{\frac{1}{d_1^v d_2^v}}. \end{aligned} \quad (\text{P.4})$$

và

$$\begin{aligned} k_2 &= V \left[\sum_{i=1}^N \frac{\alpha_i \beta_i}{d_1^v d_2^v} \right] \\ &\stackrel{(b)}{=} \sum_{i=1}^N V \left[\frac{\alpha_i}{d_1^v} \right] V \left[\frac{\beta_i}{d_2^v} \right] \\ &= \frac{N}{d_1^v d_2^v} \left(1 - \frac{\pi^2}{16} \right). \end{aligned} \quad (\text{P.5})$$

với (a) và (b) là phép biến đổi tính trung bình và phương sai của cho các biến độc lập α_i và β_i .

LỜI CẢM ƠN

Nghiên cứu này được hỗ trợ bởi các nghiên cứu viên tại Phòng thí nghiệm thông tin vô tuyến và được tài trợ bởi Học Viện Công nghệ Bưu Chính Viễn Thông dưới mã số **06-HV-2021-RD_CB2**.

TÀI LIỆU THAM KHẢO

- [1] M. Agiwal, A. Roy, and N. Saxena, "Next generation 5G wireless networks: A comprehensive survey," IEEE Communications Surveys & Tutorials, vol. 18, no. 3, pp. 1617-1655, 2016.
- [2] M. Carugi, "Key features and requirements of 5G/IMT-2020 networks," in ITU Arab Forum on Emerging Technologies, 2018.
- [3] J. Navarro-Ortiz, P. Romero-Diaz, S. Sendra, P. Ameigeiras, J. J. Ramos-Munoz, and J. M. Lopez-Soler, "A survey on 5G usage scenarios and traffic models," IEEE Communications Surveys & Tutorials, vol. 22, no. 2, pp. 905-929, 2020.
- [4] I. Vision, "Framework and overall objectives of the future development of IMT for 2020 and beyond," International Telecommunication Union (ITU), Document, Radiocommunication Study Groups, 2015.
- [5] Y. Polyanskiy, H. V. Poor, and S. Verdú, "Channel coding rate in the finite blocklength regime," IEEE Transactions on Information Theory, vol. 56, no. 5, p. 2307, 2010.
- [6] M. O. Hasna and M.-S. Alouini, "End-to-end performance of transmission systems with relays over Rayleigh-fading channels," IEEE transactions on Wireless Communications, vol. 2, no. 6, pp. 1126-1131, 2003.
- [7] J. N. Laneman, D. N. Tse, and G. W. Wornell, "Cooperative diversity in wireless networks: Efficient protocols and outage behavior," IEEE Transactions on Information theory, vol. 50, no. 12, pp. 3062-3080, 2004.
- [8] N. T. Do, D. B. da Costa, T. Q. Duong, V. N. Q. Bao, and B. An, "Opportunistic scheduling for fixed-gain amplify-and-forward-based multiuser multirelay SWIPT cooperative networks," in 2017 International Conference on Recent Advances in Signal Processing, Telecommunications & Computing (SigTelCom), 2017, pp. 49-54: IEEE.

- [9] T. Q. Duong, D. B. da Costa, M. ElKashlan, and V. N. Q. Bao, "Cognitive amplify-and-forward relay networks over Nakagami- m fading," *IEEE Transactions on Vehicular Technology*, vol. 61, no. 5, pp. 2368-2374, 2012.
 - [10] Y. Lu and W. H. Mow, "Low-complexity detection and performance analysis for decode-and-forward relay networks," in *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 4819-4823: IEEE.
 - [11] N. A. Tuan, V. N. Q. Bao, and T. T. Kien, "Performance Analysis of Energy Harvesting Two-Way Decode-and-Forward Relay Networks with Power Beacon over Nakagami- m Fading Channels," in *2018 International Conference on Advanced Technologies for Communications (ATC)*, 2018, pp. 265-269: IEEE.
 - [12] Y. Gu, H. Chen, Y. Li, L. Song, and B. Vucetic, "Short-packet two-way amplify-and-forward relaying," *IEEE Signal Processing Letters*, vol. 25, no. 2, pp. 263-267, 2017.
 - [13] V. N. Q. Bao and T. T. Thanh, "Performance Analysis of Partial Relay Selection Networks with Short Packet Communications," *The 6th NAFOSTED Conference on Information and Computer Science (NICS)*, pp. 23-26, 2019.
 - [14] O. L. A. López, E. M. G. Fernández, R. D. Souza, and H. Alves, "Ultra-reliable cooperative short-packet communications with wireless energy transfer," *IEEE Sensors Journal*, vol. 18, no. 5, pp. 2161-2177, 2018.
 - [15] E. Björnson, Ö. Ö., and E. G. Larsson, "Intelligent Reflecting Surface Versus Decode-and-Forward: How Large Surfaces are Needed to Beat Relaying?," *IEEE Wireless Communications Letters*, vol. 9, no. 2, pp. 244-248, 2020.
 - [16] Q. Wu and R. Zhang, "Intelligent Reflecting Surface Enhanced Wireless Network via Joint Active and Passive Beamforming," *IEEE Transactions on Wireless Communications*, vol. 18, no. 11, pp. 5394-5409, 2019.
 - [17] A.-A. A. Boulogeorgos and A. Alexiou, "Performance Analysis of Reconfigurable Intelligent Surface-Assisted Wireless Systems and Comparison With Relaying," *IEEE Access*, vol. 8, pp. 94463-94483, 2020.
 - [18] K. Ntontin et al., "Reconfigurable intelligent surfaces vs. relaying: Differences, similarities, and performance comparison," *arXiv preprint arXiv:1908.08747*, 2019.
 - [19] Q. Wu and R. Zhang, "Towards Smart and Reconfigurable Environment: Intelligent Reflecting Surface Aided Wireless Network," *IEEE Communications Magazine*, vol. 58, no. 1, pp. 106-112, 2020.
 - [20] W. Tang et al., "Wireless communications with reconfigurable intelligent surface: Path loss modeling and experimental measurement," *IEEE Transactions on Wireless Communications*, 2020.
 - [21] A. Papoulis and H. Saunders, "Probability, random variables and stochastic processes," 1989.
 - [22] I. S. Gradshteyn and I. M. Ryzhik, *Table of integrals, series, and products*. Academic press, 2014.
 - [23] V. N. Q. Bao and H. Y. Kong, "Error probability performance for multi-hop decode-and-forward relaying over Rayleigh fading channels," in *2009 11th International Conference on Advanced Communication Technology*, 2009, vol. 3, pp. 1512-1516: IEEE.
 - [24] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multiple-antenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, pp. 4232-4265, 2014.
 - [25] B. Makki, T. Svensson, and Z. Michele, "Finite Block-Length Analysis of the Incremental Redundancy HARQ," *IEEE Wireless Commun. Lett.*, vol. 3, no. 5, pp. 529-532, Oct. 2014.
 - [26] P. C. S. S. Freear, "Novel expressions for the Marcum and one dimensional Q-functions," *2010 7th International Symposium on Wireless Communication Systems*, 19-22 Sept. 2010.
 - [27] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multiple-antenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, p. 4232, 2014.
 - [28] Yuehua Yu, He Chen, Yonghui Li, Zhiguo Ding, and Branka Vucetic, "On the Performance of Non-Orthogonal Multiple Access in Short-Packet Communications," *IEEE Communications Letters*, vol. 22, no. 3, pp. 590-593, 2018.
 - [29] V. N. Q. Bao, *Mô phỏng hệ thống truyền thông. Hà Nội: Nhà xuất bản khoa học và kỹ thuật*, p. 267.
 - [30] A. Goldsmith, *Wireless communications* (Copyright by Cambridge University Press). Stanford University, 2005.
 - [31] B. Makki and M.-S. Alouini, "End-to-end Performance Analysis of Delay-sensitive Multi-relay Networks," *IEEE Communications Letters*, vol. 23, no. 12, pp. 2159-2163, 2019.
 - [32] S. Primak, V. Kontorovich, and V. Lyandres, "Stochastic methods and their applications to communications," *Stochastic Differential Equations Approach*. John Wiley&Sons, 2004.

DIVERSITY ORDER ANALYSIS OF INTELLIGENT REFLECTING SURFACE AND RELAY AIDED SHORT PACKET COMMUNICATIONS

Abstract— Intelligent reflecting surface (IRS) is a revolutionary technology that can greatly improve the performance of next generation wireless networks by controlling the phase/amplitude of the signal in the environmental radio via passive reflectors. In this paper, we propose a short packet communication model is assisted by intelligent reflectors. Next, we compare the performance of this system with that of a relay aided communication, where the relay node uses fixed decode and forward (FDF) technique to transmit data. To compare the performance of these two systems, we derive exact and approximate form expressions of the block error rate (BLER) over fading Rayleigh channel and also the diversity gains of both systems. Thereby, the results show that the performance of the IRS communication system is superior to that of the basic FDF communication system. Finally, we prove that the results in the theoretical analysis are completely consistent with the simulation results by the Monte-Carlo simulations.

Keywords—Intelligent reflecting surface, fading Rayleigh, decode and forward, bit error rate, short packet communications.



Nguyễn Thị Yến Linh hiện đang là giảng viên thuộc Khoa Cơ Bản 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh, nhận bằng Thạc sĩ vào năm 2008 tại Trường Khoa Học Tự Nhiên TP. HCM. Hiện nay, ThS Linh tham gia nhóm nghiên cứu tại phòng thí nghiệm thông tin vô tuyến (WCOMM). Hướng nghiên cứu chính như: Mạng ngẫu tác, thu thập năng lượng vô tuyến, bảo thông gọi tin ngắn.



Võ Nguyễn Quốc Bảo tốt nghiệp Tiến sĩ chuyên ngành vô tuyến tại Đại học Ulsan, Hàn Quốc vào năm 2010. Hiện nay, TS. Bảo là phó giáo sư của Bộ Môn Vô Tuyến, Khoa Viễn Thông 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh và đồng thời là giám đốc của phòng thí nghiệm nghiên cứu vô tuyến (WCOMM). TS. Bảo hiện là thành viên chủ chốt (senior member) của IEEE và

là tổng biên tập kỹ thuật của tạp chí REV Journal on Electronics and Communication. TS. Bảo đồng thời là biên tập viên (editor) của nhiều tạp chí khoa học chuyên ngành uy tín trong và ngoài nước, ví dụ: Transactions on Emerging Telecommunications Technologies (Wiley ETT), VNU Journal of Computer Science and Communication Engineering. TS. Bảo đã tham gia tổ chức nhiều hội nghị quốc gia và quốc tế, ví dụ: ATC (2013, 2014), NAFOSTED-NICS (2014, 2015, 2016), REV-ECIT 2015, ComManTel (2014, 2015) và SigComTel 2017. Hướng nghiên cứu hiện tại đang quan tâm bao gồm: vô tuyến nhận thức, truyền thông hợp tác, truyền song công, bảo mật lớp vật lý và thu thập năng lượng vô tuyến.



Phạm Ngọc Sơn tốt nghiệp Tiến sĩ chuyên ngành điện tử viễn thông tại Đại học Ulsan, Hàn Quốc vào năm 2015. Hiện nay, TS. Sơn là giảng viên của Bộ Môn Kỹ Thuật Máy Tính Viễn Thông, Khoa Điện – Điện Tử, Trường Đại học Sư Phạm Kỹ Thuật TP. Hồ Chí Minh (HCMUTE). Hướng nghiên cứu hiện tại đang quan tâm bao gồm: vô tuyến nhận thức, truyền thông hợp tác, truyền song công, bảo mật lớp

vật lý, thu thập năng lượng vô tuyến, đa truy cập không trực giao, mật phản xạ thông minh và truyền thông gói tin ngắn.

ĐÁNH GIÁ HIỆU NĂNG MẠNG CHUYỂN TIẾP TỪNG PHẦN VỚI ĐA ANTEN THU TRONG TRUYỀN THÔNG GÓI TIN NGẮN

Nguyễn Thị Yến Linh*, Ngô Hoàng Tú*, Võ Nguyễn Quốc Bảo*

* Khoa Cơ bản 2, khoa Viễn thông 2, Học Viện Công Nghệ Bưu Chính Viễn Thông

* Trường Đại học Giao Thông Vận Tải thành phố Hồ Chí Minh

Tóm tắt- Trong bài báo này, chúng tôi nghiên cứu mạng giải mã chuyển tiếp (DF) hai chặng trong truyền thông gói tin ngắn. Trong đó, nguồn sẽ lựa chọn một nút tốt nhất trong một tập đa nút để chuyển tiếp gói tin bằng cách sử dụng kỹ thuật lựa chọn chuyển tiếp một phần (PRS). Nguồn thu được thiết kế có M-anten và sử dụng giao thức phân tập tỉ số kết hợp cực đại (MRC) để thu nhận tín hiệu. Để đánh giá và so sánh hiệu năng hệ thống, chúng tôi đưa ra các biểu thức dạng chính xác và xấp xỉ của tỉ lệ lỗi khối (BLER) trong kênh truyền fading Rayleigh. Cuối cùng, chúng tôi thực hiện mô phỏng Monte Carlo để kiểm chứng kết quả lý thuyết và tìm ra giá trị tối ưu của số nút chuyển tiếp và số anten cũng như chứng minh các ưu điểm của mô hình hệ thống đã được đề xuất.

Từ khóa- lựa chọn chuyển tiếp từng phần, fading Rayleigh, giải mã và chuyển tiếp, tỉ lệ lỗi khối, tỉ số kết hợp cực đại, truyền thông gói tin ngắn.

I. GIỚI THIỆU

Hiện nay, truyền thông thế hệ mới thứ năm (5G) được biết đến như là sự cải tiến vượt trội xa so với các mạng thế hệ trước đây. Mạng (5G) cũng là cơ sở quyết định trong việc hiện thực hóa kỷ nguyên Internet vạn vật (IoT) và xã hội siêu kết nối. Dịch vụ chính của mạng (5G) là băng thông di động nâng cao (eMBB), truyền thông loại máy (mMTC) và truyền thông độ trễ thấp cực kỳ đáng tin cậy (uRLLC), ứng dụng trong nhiều lĩnh vực công nghiệp và xã hội [1-3]. Trong đó, uRLLC là dịch vụ trọng tâm của mạng 5G với yêu cầu độ tin cậy cực cao hơn 99.9999% và độ trễ dưới 1ms. Để đạt được các yêu cầu này, truyền thông gói ngắn với mã chiều dài khối ngắn được đưa vào hệ thống nghiên cứu như một phương pháp tiềm năng [4]. Thực vậy, các gói tin ngắn là một dạng lưu thông điển hình được tạo ra bởi những cảm biến và được trao đổi chủ yếu trong truyền thông kiểu máy. Do vậy, truyền thông gói ngắn hỗ trợ chính cho các ứng dụng 5G và IoT như kết nối đám mây đáng tin cậy, điều phối không dây từ xe đến xe, bảo động từ một bộ lớn cảm biến [4-7].

Cho đến nay, truyền thông gói ngắn đang được các nhà khoa học quan tâm. Cụ thể, Polyanskiy và các cộng sự đã tiên phong trong việc tìm ra công thức xấp xỉ của tốc độ mã hóa khối hữu hạn tối đa [8]. Từ đó, chúng ta có thể đo

hiệu suất của truyền thông gói ngắn với giá trị xấp xỉ gần đúng. Trong bài báo [9], Makki và các cộng sự đã đề xuất phương pháp tính gần đúng cho hàm Q function. Phương pháp này giúp việc tính toán tỉ số lỗi khối dễ dàng hơn. Hay các tác giả trong bài báo [10] cũng cho thấy rằng chiều dài khối thích hợp cho công suất Ergodic tối ưu nhất trên tất cả kênh fading bán tĩnh.

Bên cạnh đó, mạng chuyển tiếp ra đời với những ưu điểm như một giải pháp đầy hứa hẹn trong truyền thông vô tuyến [11], giải quyết các vấn đề về khoảng cách giữa hai thiết bị đầu cuối khi máy truyền và máy phát ở quá xa vượt ngoài khoảng công suất truyền khả dụng của máy phát hoặc có thể máy phát truyền được nhưng nếu tăng công suất phát quá lớn thì sẽ ảnh hưởng can nhiễu lớn lên các người dùng khác của hệ thống [12-14]. Nhiệm vụ của nút chuyển tiếp là thu thập tín hiệu từ nút trước nó, sau đó xử lý và chuyển tiếp tín hiệu đó đến nút tiếp theo đến khi tín hiệu đến được đích. Về cơ bản, có hai kỹ thuật xử lý tín hiệu được dùng ở nút chuyển tiếp là khuếch đại và chuyển tiếp (AF) [15-17] và giải mã và chuyển tiếp (DF) [18-20]. Các kỹ thuật này đã được nghiên cứu và ứng dụng rộng rãi trong các mạng thông tin vô tuyến như mạng thông tin di động tế bào, ad-hoc di động [21, 22], mạng cảm biến không dây [23].

Gần đây, các nhà khoa học bắt đầu quan tâm đến việc áp dụng mạng chuyển tiếp vào truyền thông sử dụng gói tin ngắn nhằm nâng cao hiệu năng hệ thống và đáp ứng các yêu cầu dịch vụ cho mạng 5G. Cụ thể, các tác giả trong [24] đã xem xét một giao thức chuyển tiếp trong đó độ lợi kênh của đường truyền trực tiếp và đường truyền có nút chuyển tiếp được tổng hợp tại máy thu theo giả định trạng thái thông tin kênh truyền hoàn hảo. Hay trong bài báo [25], các tác giả trong đã đề xuất một phương pháp "OccupyCoW" nhằm đáp ứng các yêu cầu về độ tin cậy và độ trễ cao thông qua mạng truyền thông hợp tác. Trong bài báo [26], Yulin Hu và các cộng sự đã nghiên cứu hiệu suất chuyển tiếp thông qua các kênh Rayleigh bán tĩnh dưới giả định chiều dài khối hữu hạn (FBL). Một cách cơ bản, các bài báo chủ yếu xem xét hai kịch bản chuyển tiếp trong bối cảnh FBL bao gồm kỹ thuật AF [27] và DF [28]. Bên cạnh đó, trong [29], tác giả đã chứng minh sự vượt trội của hiệu năng hệ thống sử dụng các kỹ thuật chọn lựa nút chuyển

Tác giả liên hệ: Nguyễn Thị Yến Linh

Email: linhnty.ncs@hcmute.edu.vn


Đến tòa soạn: 10/2020; chỉnh sửa: 11/2020; chấp nhận đăng: 11/2020

tiếp từng phần (PRS) và giao thức tỉ số kết hợp cực đại (MRC) trong thiết kế hệ thống với gói Ƣin dài.

Kế thừa các kết quả nghiên cứu trên và đề xuất hướng giải quyết mô hình mới trong truyền thông gói ngắn, bài báo này trước tiên tập trung vào các mạng chuyển tiếp hai chặng DF trong truyền thông gói ngắn, trong đó kỹ thuật PRS được sử dụng để truyền tín hiệu tại nút chuyển tiếp. Với mục tiêu tăng độ Ƣin cậy và độ lợi phổ, chúng tôi áp dụng giao thức MRC cho thiết kế Ƣa anten tại điểm đích. Tiếp đến, chúng tôi đưa ra các biểu thức dạng chính xác và xấp xỉ của tỉ số lỗi khối (BLER) thông qua kênh fading Rayleigh. Cuối cùng, mô phỏng Monte Carlo được thực hiện để kiểm chứng các kết quả lý thuyết và qua đó cũng chứng minh được ưu điểm hiệu năng của mô hình hệ thống mà chúng tôi đề xuất.

Phần còn lại của bài báo được trình bày như sau. Phần II sẽ trình bày mô hình của hệ thống mạng chuyển tiếp hai chặng với Ƣa nút chuyển tiếp và Ƣa anten thu tại máy thu. Phương pháp phân tích theo mô hình đề xuất để đánh giá chất lượng của hệ thống với thông số tỉ lệ lỗi khối với cả hai dạng chính xác và xấp xỉ sẽ được chứng minh trong Phần III. Phần IV, chúng tôi sẽ tiến hành mô phỏng Monte-Carlo để kiểm chứng lại các kết quả lý thuyết trong phần III. Cuối cùng là phần kết luận của bài báo.

II. MÔ HÌNH HỆ THỐNG



Hình 1 Mạng chuyển tiếp hai chặng với một user (nút nguồn), Ƣa nút chuyển tiếp và một trạm BTS (nút đích) trong truyền thông gói Ƣin ngắn.

Trong bài báo này, chúng tôi xét một mạng hai chặng bao gồm một user (đóng vai trò nguồn (S)) có một anten, N user (đóng vai trò nút chuyển tiếp) sử dụng một anten $R_n (n = \overline{1, N})^1$ và trạm thu (BTS) (đóng vai trò nguồn thu (D)) có M anten $D_m (m = \overline{1, M})^1$ như Hình 1. Giả định rằng khoảng cách nút nguồn và đích là rất lớn, S chỉ có thể truyền tín hiệu đến ở khoảng cách rất xa không có đường truyền trực tiếp giữa nguồn (S) và đích (D) bởi vì thực tế ở khoảng cách quá xa tín hiệu từ nguồn phát đến nguồn thu là rất yếu.

Quá trình truyền Ƣin từ nút nguồn và nút đích thực hiện trong hai khe thời gian liên tiếp thông qua sự trợ giúp của các nút chuyển tiếp. Trong khe thời gian đầu tiên, nút nguồn sẽ truyền tín hiệu của nó tới tất cả các nút chuyển tiếp. Tại khe thời gian này, kỹ thuật PRS được sử dụng cho

một tập N nút chuyển tiếp, chỉ có nút chuyển tiếp có tỉ số nhiều Ƣin hiệu cao nhất (SNR) mới được chọn để chuyển tiếp tín hiệu nhận được đến đích bằng kỹ thuật giải mã và chuyển tiếp (DF). Gọi R_b là nút chuyển tiếp được chọn trong bộ N nút chuyển tiếp [30, 31], chúng ta có

$$b = \arg \max_{n=\overline{1, \dots, N}} \gamma_{SR_n}, \quad (1)$$

với γ_{SR_n} là tỉ số Ƣin hiệu trên nhiều (SNR) từ $S \rightarrow R_n$. Ở đây, γ_{SR_n} tuân theo phân bố mũ và có giá trị trung bình là

$$\bar{\gamma}_{SR_n} = \frac{P_S \Omega_{SR_n}}{N_0}, \quad (2)$$

với P_S là công suất của nguồn S, Ω_{SR_n} là độ lợi kênh trung bình cho đường truyền từ S $\rightarrow R_n$ và N_0 là công suất nhiễu Gauss trắng cộng (AWGN) tại nút đích.

Giả định kênh truyền giữa nguồn và đích là kênh fading Rayleigh bán Ƣính [32] và kênh truyền từ S $\rightarrow R_n$ và $R_b \rightarrow D_m$ là các kênh truyền fading Rayleigh độc lập và đồng dạng (i.i.d). Khi đó trong chặng 1, SNR trung bình tại mỗi nhánh $\bar{\gamma}_{SR_n}$ đều bằng nhau và bằng $\bar{\gamma}_{SR}$, nghĩa là $\bar{\gamma}_{SR_n} = \bar{\gamma}_{SR}$. Dựa vào phép khai triển nhị thức trong [33], hàm phân phối tích lũy (CDF) của γ_{SR_b} có thể được đưa ra như sau

$$\begin{aligned} F_{\gamma_{SR_b}}(\gamma) &= \left[1 - \exp\left(-\frac{\gamma}{\bar{\gamma}_{SR}}\right) \right]^N \\ &= \sum_{n=1}^N (-1)^{n-1} \binom{N}{n} \left[1 - \exp\left(-\frac{n\gamma}{\bar{\gamma}_{SR}}\right) \right]. \end{aligned} \quad (3)$$

Trong khe thời gian thứ hai, nút chuyển tiếp tốt nhất R_b sử dụng kỹ thuật DF và giải mã thành công tín hiệu nhận được để truyền tín hiệu này đến đích. Tại nút đích, giao thức MRC được sử dụng nhằm cải thiện độ phân Ƣập không gian hệ thống. Do đó, SNR của tín hiệu thu được sẽ tăng tuyến tính với số lượng nhánh phân Ƣập và được xác định như sau

$$\gamma_{R_bD} = \sum_{m=1}^M \gamma_{R_bD_m}, \quad (4)$$

với $\gamma_{R_bD_m}$ là tỉ số Ƣin hiệu trên nhiều nhận tại D_m . Do giả sử kênh truyền từ $R_b \rightarrow D_m$ là các kênh truyền độc lập và đồng dạng (i.i.d), chúng tôi cũng có $\bar{\gamma}_{R_bD_m} = \bar{\gamma}_{R_bD}$.

Chúng ta có thể thấy rằng $|h_k|^2$ có phân bố mũ nên $\gamma_{R_bD_m}$ sẽ có phân bố chi bình phương với kỳ vọng là $M\bar{\gamma}_{R_bD}$ và phương sai là $2M\bar{\gamma}_{R_bD}$. Trong trường hợp này, hàm CDF của γ_{R_bD} có thể thu được như sau

¹ Giá trị $n = \overline{1, N}$ và $m = \overline{1, M}$ được sử dụng xuyên suốt bài báo.

$$\begin{aligned}\bar{\varepsilon}_{\text{SR}_b} &\approx v\sqrt{k} \sum_{n=1}^N (-1)^{n-1} \binom{N}{n} \int_{\rho_L}^{\rho_H} \left[1 - \exp\left(-\frac{n\gamma}{\bar{\gamma}_{\text{SR}}}\right) \right] d\gamma \\ &= v\sqrt{k} \sum_{n=1}^N (-1)^{n-1} \binom{N}{n} \left[(\rho_H - \rho_L) + \frac{\bar{\gamma}_{\text{SR}}}{n} \left(\exp\left(-\frac{n\rho_H}{\bar{\gamma}_{\text{SR}}}\right) - \exp\left(-\frac{n\rho_L}{\bar{\gamma}_{\text{SR}}}\right) \right) \right].\end{aligned}\quad (11)$$

$$F_{\gamma_{\text{R}_b\text{D}}}(\gamma) = 1 - \exp\left(-\frac{\gamma}{\bar{\gamma}_{\text{R}_b\text{D}}}\right) \sum_{m=1}^M \frac{\left(\frac{\gamma}{\bar{\gamma}_{\text{R}_b\text{D}}}\right)^{m-1}}{(m-1)!}. \quad (5)$$

III. ĐÁNH GIÁ HIỆU NĂNG HỆ THỐNG

Trong phần này, chúng tôi sử dụng thông số tỉ lệ lỗi khối để đánh giá hiệu năng của hệ thống sử dụng giao thức PRS và MRC trong chế độ FBL.

A. TỈ LỆ LỖI KHỐI DẠNG CHÍNH XÁC

Chúng tôi giả sử rằng tổng độ dài khối truyền là k , do có hai khe thời gian nên khối tin này sẽ được chia làm hai khối có chiều dài bằng nhau $\frac{k}{2}$. Khi S truyền β bit thông tin đến D qua hai khe thời gian tốc độ mã hóa của hệ thống được xác định là

$$r = \frac{2\beta}{k}. \quad (6)$$

Như đã được nghiên cứu trong truyền thông gói tin ngắn [34], với chiều dài khối $k \geq 100$ tỉ lệ lỗi khối BLER có thể được xấp xỉ như trong [32, CT. (59)] và [35, CT. (4)] như sau

$$\bar{\varepsilon}_X \approx E_{\gamma_X} \left\{ Q\left(\frac{C(\gamma_X) - r}{\sqrt{V(\gamma_X)/k}}\right) \right\}, \quad (7)$$

với $\bar{\varepsilon}_X$ là tốc độ lỗi khối trung bình, $X \in \{\text{SR}_b, \text{R}_b\text{D}\}$, $C(\gamma_X) = \log_2(1 + \gamma_X)$ là dung lượng kênh Shannon, $V(\gamma_X) = \left(1 - \frac{1}{(1 + \gamma_X)^2}\right)(\log_2 e)^2$ là độ phân tán kênh truyền [8], $E\{\cdot\}$ là toán tử kỳ vọng và $Q(\cdot)$ là hàm Q-

function với $Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty \exp\left(-\frac{t^2}{2}\right) dt$.

Từ (7), BLER có thể được viết lại như sau

$$\bar{\varepsilon}_X \approx \int_0^\infty Q\left(\frac{C(\gamma_X) - r}{\sqrt{V(\gamma_X)/k}}\right) f_{\gamma_X}(\gamma) d\gamma, \quad (8)$$

với $f_X(x)$ là hàm mật độ phân phối của biến ngẫu nhiên X .

Do sự phức tạp của hàm $Q\left(\frac{C(\gamma_X) - r}{\sqrt{V(\gamma_X)/k}}\right)$ nên rất khó để tìm ra biểu thức dạng đóng cho công thức (8). Do đó,

chúng tôi lấy xấp xỉ hàm $Q(\cdot)$ như trong [34, CT. (14)],

đó là $Q\left(\frac{C(\gamma_X) - r}{\sqrt{V(\gamma_X)/k}}\right) \approx Z(\gamma_X)$, với

$$Z(\gamma_X) = \begin{cases} 1 & \gamma_X \leq \rho_L \\ \frac{1}{2} - v\sqrt{k}(\gamma_X - \theta) & \rho_L < \gamma_X < \rho_H \\ 0 & \gamma_X \geq \rho_H \end{cases}, \quad (9)$$

với $v = \frac{1}{2\pi\sqrt{2^{2r} - 1}}$, $\theta = 2^r - 1$, $\rho_H = \theta + \frac{1}{2v\sqrt{k}}$ và $\rho_L = \theta - \frac{1}{2v\sqrt{k}}$.

Bằng cách thay (9) vào (8), chúng ta có

$$\begin{aligned}\bar{\varepsilon}_X &\approx \int_0^\infty Z(\gamma_X) f_{\gamma_X}(\gamma) d\gamma = \int_0^\infty Z(\gamma_X) dF_{\gamma_X}(\gamma) \\ &= \left[Z(\gamma_X) F_{\gamma_X}(\gamma) \right]_{\gamma=0}^{\gamma=\infty} - \int_0^\infty F_{\gamma_X}(\gamma) dZ(\gamma_X) \quad (10) \\ &= v\sqrt{k} \int_{\rho_L}^{\rho_H} F_{\gamma_X}(\gamma) d\gamma.\end{aligned}$$

Thay (3) vào (10), ta được tốc độ lỗi khối cho khe thời gian thứ nhất như trong (11).

Đối với khe thời gian thứ hai, ta cũng thực hiện tương tự. Thay (5) vào (10), tỉ số lỗi khối BLER ở khe thời gian thứ hai được đưa ra như trong (12), trong đó $\Upsilon(\text{gg})$ là hàm Gamma không hoàn thành với $\Upsilon(m, x) = \int_0^x t^{m-1} \exp(-t) dt$ được xác định như trong [33].

$$\begin{aligned}\bar{\varepsilon}_{R_b,D} &\approx v\sqrt{k} \int_{\rho_L}^{\rho_H} \left[1 - \exp\left(-\frac{\gamma}{\bar{\gamma}_{R_b,D}}\right) \sum_{m=1}^M \frac{\left(\frac{\gamma}{\bar{\gamma}_{R_b,D}}\right)^{m-1}}{(m-1)!} \right] d\gamma = v\sqrt{k} \int_{\frac{\rho_L}{\bar{\gamma}_{R_b,D}}}^{\frac{\rho_H}{\bar{\gamma}_{R_b,D}}} \left[1 - \sum_{m=1}^M \frac{1}{(m-1)!} t^{m-1} \exp(-t) \right] \bar{\gamma}_{R_b,D} dt \\ &= v\sqrt{k} \left[\rho_H - \rho_L - \sum_{m=1}^M \frac{\bar{\gamma}_{R_b,D}}{(m-1)!} \left(\Upsilon\left(m, \frac{\rho_H}{\bar{\gamma}_{R_b,D}}\right) - \Upsilon\left(m, \frac{\rho_L}{\bar{\gamma}_{R_b,D}}\right) \right) \right],\end{aligned}\quad (12)$$

$$\begin{aligned}\mathcal{B}_{R_b,D} &\approx v\sqrt{k} \int_{\rho_L}^{\rho_H} \left[1 - \sum_{m=1}^M \frac{1}{(m-1)!} \left(\frac{\gamma}{\bar{\gamma}_{R_b,D}}\right)^{m-1} \sum_{i=0}^M \frac{(-1)^i}{i!} \left(\frac{\gamma}{\bar{\gamma}_{R_b,D}}\right)^i \right] d\gamma = v\sqrt{k} \int_{\rho_L}^{\rho_H} \left[1 - \sum_{m=1}^M \frac{1}{\bar{\gamma}_{R_b,D}^{m-1} (m-1)!} \sum_{i=0}^M \frac{(-1)^i}{\bar{\gamma}_{R_b,D}^{m-1} i!} \gamma^{i+m-1} \right] d\gamma \\ &= v\sqrt{k} \left[\rho_H - \rho_L - \sum_{m=1}^M \frac{1}{\bar{\gamma}_{R_b,D}^{m-1} (m-1)!} \sum_{i=0}^M \frac{(-1)^i}{\bar{\gamma}_{R_b,D}^{m-1} i!} \frac{\rho_H^{i+m} - \rho_L^{i+m}}{i+m} \right].\end{aligned}\quad (18)$$

Nếu các nút chuyển tiếp sử dụng kỹ thuật giải mã và chuyển tiếp có lựa chọn (SDF) thì tốc độ lỗi khối BLER toàn trình (e2e) có thể được tính thông qua (11) và (12) như sau

$$\bar{\varepsilon}_{e2e(SDF)} = \bar{\varepsilon}_{SR_b} + (1 - \bar{\varepsilon}_{SR_b}) \bar{\varepsilon}_{R_b,D}. \quad (13)$$

Trong khi đó, nếu các nút chuyển tiếp sử dụng kỹ thuật giải mã và chuyển tiếp cố định (FDF) thì tốc độ lỗi khối BLER toàn trình e2e sẽ được tính như sau

$$\bar{\varepsilon}_{e2e(FDF)} = \bar{\varepsilon}_{SR_b} (1 - \bar{\varepsilon}_{R_b,D}) + (1 - \bar{\varepsilon}_{SR_b}) \bar{\varepsilon}_{R_b,D}. \quad (14)$$

B. TỈ LỆ LỖI KHỐI DẠNG XẤP XỈ

Tiếp theo, chúng tôi sẽ trình bày dạng xấp xỉ của tỉ lệ lỗi khối để có đánh giá khách quan hơn về hiệu năng của hệ thống ở mức SNR trung bình $\bar{\gamma}$ cao. Dạng xấp xỉ này được xem như là một đường giới hạn trên (upper bound) cho các giá trị của tỉ lệ lỗi khối khi càng tăng SNR trung bình tiến ra vô cùng. Điều này có nghĩa là tỉ lệ lỗi khối toàn trình của hệ thống luôn đạt giá trị nhỏ hơn hoặc bằng giá trị đường giới hạn trên này cho dù có tăng SNR trung bình thế nào đi chăng nữa. Mặt khác, đây cũng là điều mà chúng ta mong muốn vì tỉ lệ lỗi khối càng nhỏ thì hiệu năng hệ thống càng được cải thiện.

Áp dụng vô cùng bé tương đương tại $x \rightarrow 0$ cho hàm $1 - \exp(-x)$ và khai triển Maclaurin cho hàm $\exp(-x)$ [36] như sau

$$1 - \exp(-x) : x \quad (15)$$

$$\text{và} \quad \exp(-x) \approx \sum_{i=0}^{\psi} \frac{(-1)^i}{i!} x^i + O[x]^{\psi}, \quad (16)$$

với ψ là số bậc khai triển và $O[x]^{\psi}$ là phần dư Peano trong khai triển Maclaurin [37].

Như vậy, thay (15) vào (10), biểu thức dạng xấp xỉ của tỉ lệ lỗi khối BLER ở khe thời gian đầu tiên như sau

$$\mathcal{B}_{SR_b} \approx v\sqrt{k} \int_{\rho_L}^{\rho_H} \left(\frac{\gamma}{\bar{\gamma}_{SR}}\right)^N d\gamma = \frac{v\sqrt{k}}{N+1} \left(\frac{\rho_H^{N+1} - \rho_L^{N+1}}{\bar{\gamma}_{SR}^N}\right). \quad (17)$$

Trong khe thời gian thứ hai, chúng ta cần xem xét bậc phân tập của hệ thống. Như đã biết, bậc phân tập tối đa của một hệ thống có M anten là M và khi bậc phân tập bằng với M , hệ thống được cho là đạt được bậc phân tập đầy đủ [37]. Trong trường hợp này, áp dụng (16) vào (5), sau đó thay vào (10), tỉ lệ lỗi khối BLER dạng xấp xỉ ở khe thời gian thứ hai có thể được tính như trong (18).

Mặt khác, ta cũng dễ thấy rằng giá trị của tỉ lệ lỗi khối từng chặng $\bar{\varepsilon}_{SR_b}$ và $\bar{\varepsilon}_{R_b,D}$ rất nhỏ khi công suất nguồn phát càng lớn, nghĩa là $\bar{\varepsilon}_{SR_b} \bar{\varepsilon}_{R_b,D} \approx 0$. Do đó, ta có thể viết lại tỉ lệ lỗi khối toàn trình dạng xấp xỉ từ (13) và (14) như sau

$$\mathcal{B}_{e2e(SDF)} \approx \mathcal{B}_{e2e(FDF)} \approx \mathcal{B}_{SR_b} + \mathcal{B}_{R_b,D}. \quad (19)$$

IV. KẾT QUẢ MÔ PHỎNG VÀ THẢO LUẬN

Trong phần này, chúng tôi sử dụng phương pháp mô phỏng Monte-Carlo trên phần mềm Matlab cho mô hình đề xuất để kiểm chứng lại các kết quả lý thuyết đã được trình bày ở phần III [38]. Đặc biệt, chúng tôi sẽ thảo luận về các đặc điểm hiệu năng hệ thống cũng như các thông số thiết kế hệ thống tối ưu cho mô hình mà chúng tôi đề xuất.

Các thông số được chúng tôi sử dụng để thực hiện mô phỏng như số bit thông tin là $\beta = 256$ bit và chiều dài khối $m = 256$. Để việc tính toán đơn giản chúng tôi giả định rằng tổng khoảng cách truyền được chuẩn hóa với $D = 10$. Với giả định phân bố vị trí nút chuyển tiếp ở ngay chính giữa nút nguồn và nút đích, khoảng cách đường truyền từ $S \rightarrow R_n$ và $R_b \rightarrow D$ là $d_1 = d_2 = \frac{D}{2}$. Hơn nữa, chúng tôi giả sử xem xét mô hình suy hao đường truyền đơn giản [37] và kênh truyền thực tế với


$$\Omega_{SR} = \Omega_{R_b,D} = \left(\frac{D}{2}\right)^{-\eta} \text{ với } \eta = 3 \text{ là hệ số suy hao đường}$$

truyền. Mặt khác, chúng tôi gọi $\bar{\gamma} = \frac{P}{N_0}$ là SNR trung

bình của nguồn phân bổ năng lượng với P là tổng năng lượng được phân bổ. Do N_0 là hằng số nên chúng ta có thể hiểu rằng khi tăng SNR cũng có nghĩa là ta tăng công suất phát của nguồn cung cấp năng lượng. Trong mô hình này, chúng tôi giả sử hệ thống có phân bổ công suất đồng đều cho các nút phát trong mỗi chặng, nghĩa là


$$P_s = P_{r_b} = \frac{P}{2}.$$

Đầu tiên, chúng tôi so sánh tỉ lệ lỗi khối BLER toàn trình trong hai trường hợp sử dụng kỹ thuật giải mã và chuyển tiếp cố định FDF và kỹ thuật giải mã và chuyển tiếp có chọn lọc SDF. Tỉ lệ lỗi khối toàn trình BLER được khảo sát như là một hàm của SNR trung bình $\bar{\gamma}$ với giả sử cố định số lượng nút chuyển tiếp $N = 2$ và số lượng anten tại máy thu $M = 2$ như trong Hình 2.



Hình 2 So sánh BLER giữa hai kỹ thuật SDF và FDF.

Dễ thấy, kết quả mô phỏng (Simulation) hoàn toàn trùng khớp với kết quả lý thuyết (Analysis) và kết quả đường xấp xỉ (Asymptotic) hội tụ với các giá trị đường lý thuyết ở SNR trung bình cao, điều này chứng minh các kết quả phân tích lý thuyết của chúng tôi trong phần III là hoàn toàn chính xác. Từ Hình 2, chúng ta có thể dễ dàng nhận ra rằng tỉ lệ lỗi khối khi sử dụng kỹ thuật giải mã và chuyển tiếp cố định FDF nhỏ hơn so với khi sử dụng kỹ thuật giải mã và chuyển tiếp có chọn lọc SDF ở dải SNR trung bình $\bar{\gamma}$ thấp. Hay nói cách khác, hiệu năng hệ thống khi sử dụng kỹ thuật FDF tốt hơn so với kỹ thuật SDF ở dải giá trị SNR trung bình $\bar{\gamma}$ thấp, cụ thể là dưới 10 dB như trong Hình 2. Tuy nhiên, từ giá trị SNR trung bình $\bar{\gamma}$ cao hơn 10 dB, hiệu suất hệ thống của hai kỹ thuật là như nhau. Mặc dù, ở giá trị SNR trung bình cao, hiệu suất hệ thống của hai kỹ thuật này tương đương nhau nhưng chúng ta vẫn không thể phủ nhận rằng hiệu suất của kỹ thuật FDF tốt hơn so với kỹ thuật SDF về tổng thể trong toàn dải SNR trung bình $\bar{\gamma}$. Do đó, chúng tôi sẽ sử dụng kỹ thuật FDF để mô phỏng cho tất cả các khảo sát tiếp theo.



Hình 3 Ảnh hưởng chiều dài khối tin k lên hiệu năng hệ thống với $M = 2$ và $N = 2$.


Tiếp theo, chúng tôi khảo sát tỉ lệ lỗi khối BLER là một hàm theo độ dài khối tin k như Hình 3 với các giá trị SNR trung bình $\bar{\gamma}$ tăng lần lượt là 10, 15 và 20 dB. Các giá trị của $N = 2$ và $M = 2$ được sử dụng để mô phỏng trong hình này. Một lần nữa, các kết quả mô phỏng hoàn toàn trùng khớp với các kết quả lý thuyết và xác minh được tính đúng đắn trong phân tích lý thuyết của chúng tôi. Quan sát Hình 3, chúng ta có thể thấy rằng khi tăng giá trị của chiều dài khối tin k và SNR trung bình $\bar{\gamma}$ thì hiệu năng hệ thống sẽ được cải thiện đáng kể. Hơn nữa, chúng ta đang khảo sát chế độ FBL với $k \geq 100$ và để tính được giới hạn của hàm BLER toàn trình khi $k \rightarrow +\infty$ là $\lim_{k \rightarrow +\infty} \text{BLER}_{e2e} = 0$. Điều này có nghĩa là chúng ta không tìm được giá trị k tối ưu xác định nào hết và làm chúng ta phải lưu ý rằng chiều dài khối tin k vừa được đánh giá là càng tăng càng tốt, trong khi mục tiêu của truyền thông gói ngắn đó là độ dài khối càng ngắn thì độ trễ truyền sẽ được giảm. Do đó, chúng ta phải cân nhắc trong cả hai tình huống về ưu nhược điểm của việc tăng hoặc giảm k , chúng ta sẽ chọn giá trị k cụ thể phụ thuộc vào một yêu cầu chất lượng dịch vụ cụ thể. Ví dụ, một dịch vụ thoại yêu cầu tỉ lệ lỗi khối tối đa là 6×10^{-3} , thì giá trị của k được chọn ứng với từng trường hợp công suất phát 10, 15 và 20 dB là khoảng 1000, 400 và 200.

Tiếp theo, chúng tôi so sánh sự ảnh hưởng của số lượng nút chuyển tiếp N và số anten M lên hiệu năng hệ thống sử dụng kỹ thuật FDF qua Hình 4. Chúng tôi lựa chọn các giá trị của N và M cụ thể trong các trường hợp so sánh như sau:

- $N = 1$ và $M = 2$ cho trường hợp $N < M$.
- $N = 5$ và $M = 3$ cho trường hợp $N > M$.
- $N = M = 6$ cho trường hợp $N = M$.


Hình 4 cho chúng ta thấy rõ rằng tỉ lệ lỗi khối toàn trình sẽ gần bằng với tổng tỉ lệ lỗi khối của cả hai chặng trong trường hợp ii) và iii) tương ứng với $N > M$ và $N = M$. Tuy nhiên, trong trường hợp i) với $N < M$, tỉ lệ lỗi khối toàn trình chỉ gần bằng tỉ lệ lỗi khối chặng 1 từ $S \rightarrow R_n$. Điều này có nghĩa là với số lượng N và M cho trước với $N < M$, chúng ta chỉ cần thực hiện tính toán tỉ lệ lỗi khối chặng 1 là có thể ước lượng được hiệu năng toàn hệ thống.

Đóng góp này có thể giúp chúng ta giảm thiểu được khối lượng tính toán phức tạp của thông số tỉ lệ lỗi khối trong chặng 2 từ $R_b \rightarrow D_m$ trong trường hợp triển khai thực tế đã có sẵn số lượng N và M với $N < M$. Qua đó, chúng ta cũng thấy được tầm quan trọng của số lượng nút chuyển tiếp và số lượng anten trong triển khai thiết kế hệ thống.




Hình 4 So sánh sự ảnh hưởng của số lượng nút chuyển tiếp N và số anten M lên hiệu năng hệ thống.

Do đó, trong Hình 5 và Hình 6, chúng tôi khảo sát riêng lẻ mức độ ảnh hưởng của số lượng anten tại máy thu M và số lượng nút chuyển tiếp N lên hiệu năng hệ thống. Mục tiêu là tìm ra thông số thiết kế tối ưu cho M và N . Một cách khách quan, trong cả hai hình, các kết quả lý thuyết hoàn toàn trùng khớp với kết quả mô phỏng. Điều này một lần nữa cho thấy các biểu thức phân tích của chúng tôi trong phần III là hoàn toàn chính xác.



Hình 5 Ảnh hưởng của số lượng anten M lên hiệu năng hệ thống với $N = 2$.




Hình 6 Ảnh hưởng của số lượng nút chuyển tiếp N lên hiệu năng hệ thống với $M = 3$.

Cụ thể, Hình 5 chúng tôi khảo sát BLER là một hàm theo số lượng anten tại máy thu M với giả sử cố định số lượng nút chuyển tiếp $N = 2$. Từ Hình 5, chúng ta có thể thấy BLER giảm khi tăng SNR trung bình $\bar{\gamma}$. Ảnh hưởng đối với các giá trị của M anten tại máy thu: i) khi $M < 3$ thì BLER giảm đáng kể hay nói cách khác là hiệu năng hệ thống được cải thiện đáng kể; ii) trong khi $M \geq 3$ thì BLER vẫn duy trì một mức giá trị không đổi. Mặt khác, trong thiết kế và triển khai hệ thống, đương nhiên là chúng ta sẽ mong muốn triển khai hệ thống sao cho hiệu năng tốt nhất mà lại ít thiết bị nhất có thể để tiết kiệm chi phí. Do đó trong trường hợp này, $M = 3$ là thông số thiết kế tối ưu nhất của số lượng anten tại máy thu đảm bảo được hai tiêu chí đã được đề cập là tối ưu hiệu năng và tiết kiệm chi phí triển khai nhất có thể.

Tương tự, trong Hình 6, chúng tôi khảo sát BLER là một hàm theo số lượng nút chuyển tiếp N với giả sử cố định số lượng anten tại máy thu. Chúng tôi sẽ sử dụng giá trị tối ưu $M = 3$ vừa tìm được trong khảo sát Hình 5 cho thiết kế thông số hệ thống. Suy luận một cách tương tự, chúng ta cũng có: i) với $N < 4$ thì hiệu năng hệ thống được cải thiện đáng kể; ii) với $N \geq 4$, BLER không còn giảm nữa. Khi đó, giá trị số lượng nút chuyển tiếp $N = 4$ sẽ được chọn làm giá trị tối ưu cho các thiết kế hệ thống.

Cuối cùng, chúng tôi sử dụng các giá trị tối ưu $N = 4$ và $M = 3$ đã được khảo sát trong Hình 5 và Hình 6 để khảo sát hiệu năng hệ thống. Và cũng như đã đề cập, giá trị của chiều dài khối k chỉ được chọn cụ thể phù hợp với một yêu cầu dịch vụ cụ thể. Trong Hình 7 này, chúng tôi khảo sát tỉ lệ lỗi khối BLER là một hàm theo SNR trung bình $\bar{\gamma}$ ba trường hợp tượng trưng điển hình của k là $k = 256$, $k = 512$ và $k = 1024$. Trong Hình 7, chúng ta có thể thấy rằng các đường phân tích lý thuyết bao gồm cả đường BLER dạng chính xác và dạng xấp xỉ đều hoàn toàn khớp với các kết quả mô phỏng. Hơn nữa, đường xấp xỉ hội tụ với đường phân tích lý thuyết và đường mô phỏng ở dải công suất phát cao cũng cho thấy rằng các giá trị của tỉ lệ lỗi khối luôn đạt giá trị nhỏ hơn hoặc bằng giá trị đường xấp xỉ này cho dù có tăng SNR trung bình thế nào đi chăng nữa. Ngoài ra, cũng dễ thấy rằng khi SNR trung bình $\bar{\gamma}$ càng tăng thì BLER càng giảm trong tất cả các trường hợp của k , kết hợp với phân tích đường xấp xỉ vừa rồi, chúng

ta có thể kết luận rằng hiệu năng hệ thống luôn luôn được cải thiện khi chúng ta càng tăng SNR trung bình và luôn không vượt quá giá trị của đường giới hạn trên (đường xấp xỉ). Điều này đúng như chúng ta mong đợi. Mặc dù tăng công suất phát làm cho hiệu năng hệ thống được cải thiện nhưng chúng ta cũng không nên lạm dụng tăng công suất phát quá lớn sẽ có thể ảnh hưởng can nhiễu lớn lên các người dùng khác của hệ thống.



Hình 7 Ảnh hưởng của giá trị SNR trung bình lên hiệu năng hệ thống với $M = 3$ và $N = 4$.

V. KẾT LUẬN

Trong bài báo này, chúng tôi đề xuất mô hình mạng giải mã chuyên tiếp DF hai chặng kết hợp sử dụng kỹ thuật PRS cho đa nút chuyên tiếp và kỹ thuật MRC cho đa anten được thiết kế tại nút đích. Đặc biệt, chúng tôi tìm ra được các biểu thức tỉ lệ lỗi khối dạng chính xác và xấp xỉ qua kênh truyền fading Rayleigh và sử dụng mô phỏng Monte Carlo để kiểm chứng tính chính xác của mô hình đề xuất. Các kết luận chính của hệ thống như sau

- i) Với cùng một công suất nguồn phát thì hiệu năng hệ thống của FDF bằng với SDF ở giá trị SNR trung bình cao, trong khi với dải SNR trung bình thấp thì hiệu năng hệ thống của FDF tốt hơn hệ thống áp dụng kỹ thuật SDF.
- ii) Giá trị tối ưu của số lượng nút chuyên tiếp và số lượng anten tại máy thu tương ứng là 4 và 3 cho thiết kế hệ thống mô hình mà chúng tôi đề xuất. Ngoài ra, giả sử trong trường hợp triển khai thực tế đã có sẵn số lượng N và M với $N < M$, chúng ta sẽ giảm thiểu được khối lượng tính toán phức tạp của thông số tỉ lệ lỗi khối toàn trình. Tỉ lệ lỗi khối toàn trình trong trường hợp này sẽ gần bằng giá trị tỉ lệ lỗi khối của chặng truyền có chứa N nút chuyên tiếp.
- iii) Đối với chiều dài khối tin k , chúng ta chỉ xác định được k cụ thể trong một trường hợp yêu cầu chất lượng dịch vụ cụ thể.
- iv) Cuối cùng là khi càng tăng $\bar{\gamma}$ thì hiệu năng hệ thống càng được cải thiện đúng như mong đợi. Tuy nhiên, chúng ta cũng không nên lạm dụng tăng công suất phát quá lớn sẽ có thể ảnh hưởng can nhiễu lớn lên các người dùng khác của hệ thống.

LỜI CẢM ƠN

Nghiên cứu này được hỗ trợ bởi các nghiên cứu viên tại Phòng thí nghiệm thông tin vô tuyến và được tài trợ bởi Học Viện Công nghệ Bưu Chính Viễn Thông dưới mã số 07-HV-2020-RD_CB2.

TÀI LIỆU THAM KHẢO

- [1] P. Nouri, Hirley Alves, and Matti Latva-aho., "On the performance of ultra-reliable decode and forward relaying under the finite blocklength," presented at the 2017 European Conference on Networks and Communications (EuCNC), 2017.
- [2] Petar Popovski, Cedomir Stefanovi, Jimmy J. Nielsen, Elisabeth de Carvalho, Marko Angelichinoski, Kasper F. Trillingsgaard, and Alexandru-Sabin Bana, "Wireless access for ultra-reliable low-latency communication: Principles and building blocks," *IEEE Network* vol. 32, no. 2, pp. 16-23, 2018.
- [3] Luigi Atzori, Antonio Iera, Giacomo Morabito, "The internet of things: A survey," *Computer networks*, vol. 54, no. 15, pp. 2787-2805, 2010.
- [4] E. Dahlman, Gunnar Mildh, Stefan Parkvall, Janne Peisa, Joachim Sachs, Yngve Selén, and Johan Sköld, "5G wireless access: requirements and realization," *IEEE Communications Magazine* vol. 52, no. 12, pp. 42-47, 2014.
- [5] S. C. a. J. Zhao, "The requirements, challenges, and technologies for 5G of terrestrial mobile telecommunication," *IEEE Communications Magazine*, vol. 52, no. 5, pp. 36-43, 2014.
- [6] K. Begum, and Sunanda Dixit, "Industrial WSN using IoT: A survey," in *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*, 2016: IEEE.
- [7] A. Botta, et al., "Integration of cloud computing and internet of things: a survey," *Future generation computer systems* vol. 56, pp. 684-700, 2016.
- [8] Y. Polyanskiy, H. V. Poor, and S. Verdú, "Channel coding rate in the finite blocklength regime," *IEEE Transactions on Information Theory*, vol. 56, no. 5, p. 2307, 2010.
- [9] B. Makki, T. Svensson, and M. Zorzi, "Finite block-length analysis of the incremental redundancy HARQ," *IEEE Wireless Communications Letters*, vol. 3, no. 5, pp. 529-532, 2014.
- [10] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multiple-antenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, pp. 4232-4265, 2014.
- [11] A. Nosratinia, Todd E. Hunter, and Ahmadrza Hedayat., "Cooperative communication in wireless networks," *IEEE communications Magazine*, vol. 42, no. 10, pp. 74-80, 2004.

- [12] P. Zhang, et al, "Cooperative localization in 5G networks: A survey," *Ict Express* vol. 3, no. 1, pp. 27-32, 2017.
- [13] E. Ahmed, and Hamid Gharavi, "Cooperative vehicular networking: A survey," *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 3, pp. 996-1014, 2018.
- [14] K. Cichoń, Adrian Kliks, and Hanna Bogucka, "Energy-efficient cooperative spectrum sensing: A survey," *IEEE Communications Surveys & Tutorials* vol. 18, no. 3, pp. 1861-1886, 2016.
- [15] S. Dang, et al., "OFDM-IM based dual-hop system using fixed-gain amplify-and-forward relay with pre-processing capability," *IEEE Transactions on Wireless Communications*, vol. 18, no. 4, pp. 2259-2270, 2019.
- [16] Nhu Tri Do, Daniel Benevides da Costa, Trung Q. Duong, Vo Nguyen Quoc Bao, and Beongku An, "Opportunistic scheduling for fixed-gain amplify-and-forward-based multiuser multirelay SWIPT cooperative networks," presented at the 2017 International Conference on Recent Advances in Signal Processing, Telecommunications & Computing (SigTelCom), 2017.
- [17] T. Q. Duong, Daniel Benevides da Costa, Maged ElKashlan, and Vo Nguyen Quoc Bao, "Cognitive amplify-and-forward relay networks over Nakagami-m fading," *IEEE Transactions on Vehicular Technology* vol. 61, no. 5, pp. 2368-2374, 2012.
- [18] Dac-Binh Ha, Tung Thanh Vu, Tran Trung Duy, and Vo Nguyen Quoc Bao, "Secure cognitive reactive decode-and-forward relay networks: With and without eavesdropper," *Wireless Personal Communications* vol. 85, no. 4, pp. 2619-2641, 2015.
- [19] N. A. Tuan, Vo Nguyen Quoc Bao, and Truong Trung Kien, "Performance Analysis of Energy Harvesting Two-Way Decode-and-Forward Relay Networks with Power Beacon over Nakagami-m Fading Channels," presented at the 2018 International Conference on Advanced Technologies for Communications (ATC), 2018.
- [20] Y. Lu, and Wai Ho Mow, "Low-complexity Detection and Performance Analysis for Decode-and-forward Relay Networks," presented at the ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2019.
- [21] B. An, Tran Trung Duy, and Hyung-Yun Kong, "A cooperative transmission strategy using entropy-based relay selection in mobile ad-hoc wireless sensor networks with Rayleigh fading environments," *KSII Transactions on Internet and Information Systems (TIIS)*, vol. 3, no. 2, pp. 147-162, 2009.
- [22] B. An and T. T. Duy, "A cooperative routing in mobile ad-hoc wireless sensor networks with Rayleigh fading environments," in *2010 International Symposium on Computer, Communication, Control and Automation (3CA)*, 2010, vol. 1, pp. 22-25: IEEE.
- [23] T. D. Hieu, T. T. Duy, and S. G. Choi, "Performance evaluation of relay selection schemes in beacon-assisted dual-hop cognitive radio wireless sensor networks under impact of hardware noises," *Sensors*, vol. 18, no. 6, p. 1843, 2018.
- [24] Y. Hu, James Gross, and Anke Schmeink, "On the Performance Advantage of Relaying Under the Finite Blocklength Regime," *IEEE Communications Letters* vol. 19, no. 5, pp. 779-782, 2015.
- [25] V. N. Swamy, Sahaana Suri, Paul Rigge, Matthew Weiner, Gireeja Ranade, Anant Sahai and Borivoje Nikoli, "Cooperative communication for high-reliability low-latency wireless control," presented at the 2015 IEEE International Conference on Communications (ICC), 2015.
- [26] Y. Hu, Anke Schmeink, and James Gross, "Blocklength-limited performance of relaying under quasi-static Rayleigh channels," *IEEE Transactions on Wireless Communications* vol. 15, no. 7, pp. 4548-4558, 2016.
- [27] Y. Gu, H. Chen, Y. Li, L. Song, and B. Vucetic, "Short-Packet Two-Way Amplify-and-Forward Relaying," *IEEE Signal Processing Letters*, vol. 25, no. 2, pp. 263-267, 2018.
- [28] O. L. A. López, R. D. Souza, H. Alves, and E. M. G. Fernández, "Ultra reliable short message relaying with wireless power transfer," in *2017 IEEE International Conference on Communications (ICC)*, 2017, pp. 1-6: IEEE.
- [29] V. N. Q. Bao, D. H. Bac, L. Q. Cuong, L. Q. Phu, and T. D. Thuan, "Performance analysis of partial relay selection with multi-antenna destination cooperation," presented at the ICTC 2011, 2011, September.
- [30] Ioannis Krikidis, John Thompson, Steve McLaughlin, and Norbert Goertz, "Amplify-and-forward with partial relay selection," *IEEE Communications letters*, vol. 12, no. 4, pp. 235-237, 2008.
- [31] V. N. Q. Bao and H. Y. Kon, "Diversity order analysis of dual-hop relaying with partial relay selection," *IEICE transactions on communications*, vol. 92, no. 12, pp. 3942-3946, 2009.
- [32] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multipleantenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, p. 4232, 2014.
- [33] I. S. Gradshteyn, and I. M. Ryzhik, *Table of Integrals, Series, and Products*, 7th ed. 2007.
- [34] B. Makki, T. Svensson, and Z. Michele, "Finite Block-Length Analysis of the Incremental Redundancy HARQ," *IEEE Wireless Commun. Lett.*, vol. 3, no. 5, pp. 529-532, Oct. 2014.

- [35] Yuehua Yu, He Chen, Yonghui Li, Zhiguo Ding, and Branka Vucetic, "On the Performance of Non-Orthogonal Multiple Access in Short-Packet Communications," *IEEE Communications Letters*, vol. 22, no. 3, pp. 590-593, 2018.
- [36] G. Strang and E. P. Herman, "Calculus: Volume 1 OpenStax," 2018.
- [37] A. Goldsmith, *Wireless communications* (Copyright by Cambridge University Press). Stanford University, 2005.
- [38] V. N. Q. Bao, *Mô phỏng hệ thống truyền thông*. Hà Nội: Nhà xuất bản khoa học và kỹ thuật, p. 267.

BLOCK ERROR RATE ANALYSIS OF DUAL-HOP NETWORK WITH MULTIPLE RELAYS AND MULTIPLE RECEIVED ANTENNAS UNDER SHORT PACKET COMMUNICATIONS

Abstract— This research investigates the effect of dual-hop decode-and-forward (DF) relay networks with a partial relay selection (PRS) strategy and maximal ratio combining (MRC) protocol under short packet communications, where the destination's M -antenna is designed. For performance evaluation and comparison, we derive the exact and asymptotic closed-form expressions of block error rate (BLER) over Rayleigh fading channel. Eventually, we perform Monte Carlo simulations to verify our theoretical results and figure out the optimal value of relay numbers and antenna numbers as well as demonstrate the advantages of our proposed system model.

Keywords—Block error rate, dual-hop network, partial relay selection, maximal ratio combining, short packet communications.



Nguyễn Thị Yến Linh hiện đang là giảng viên thuộc Khoa Cơ Bản 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh, nhận bằng Thạc sĩ vào năm 2008 tại Trường Khoa Học Tự Nhiên TP. HCM. Hiện nay, ThS Linh tham gia nhóm nghiên cứu tại phòng thí nghiệm thông tin vô

tuyến (WCOMM). Hướng nghiên cứu chính như: Mạng ngẫu nhiên, thu thập năng lượng vô tuyến, bảo mật lớp vật lý.



Ngô Hoàng Tú tốt nghiệp kỹ sư chuyên ngành Truyền thông và mạng máy tính tại Đại học Giao Thông Vận Tải thành phố Hồ Chí Minh vào năm 2020. Hiện nay, Ngô Hoàng Tú đang là giảng viên của bộ môn Kỹ thuật máy tính, Khoa Công nghệ thông tin, trường Đại học Giao Thông Vận Tải thành phố Hồ

Chí Minh. Hướng nghiên cứu hiện tại đang quan tâm bao

gồm: vô tuyến nhận thức, truyền thông hợp tác, đa truy nhập không trực giao và truyền thông gói tin ngắn.



Võ Nguyễn Quốc Bảo tốt nghiệp Tiến sĩ chuyên ngành vô tuyến tại Đại học Ulsan, Hàn Quốc vào năm 2010. Hiện nay, TS. Bảo là phó giáo sư của Bộ Môn Vô Tuyến, Khoa Viễn Thông 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh và đồng thời là giám đốc của phòng thí

nghiệm nghiên cứu vô tuyến (WCOMM). TS. Bảo hiện là thành viên chủ chốt (senior member) của IEEE và là tổng biên tập kỹ thuật của tạp chí REV Journal on Electronics and Communication. TS. Bảo đồng thời là biên tập viên (editor) của nhiều tạp chí khoa học chuyên ngành uy tín trong và ngoài nước, ví dụ: Transactions on Emerging Telecommunications Technologies (Wiley ETT), VNU Journal of Computer Science and Communication Engineering. TS. Bảo đã tham gia tổ chức nhiều hội nghị quốc gia và quốc tế, ví dụ: ATC (2013, 2014), NAFOSTED-NICS (2014, 2015, 2016), REV-ECIT 2015, ComManTel (2014, 2015), và SigComTel 2017. Hướng nghiên cứu hiện tại đang quan tâm bao gồm: vô tuyến nhận thức, truyền thông hợp tác, truyền song công, bảo mật lớp vật lý và thu thập năng lượng vô tuyến.

Performance Evaluation of Simultaneously Transmitting and Reflecting Intelligent Reflecting Surface - Assisted NOMA Networks for Short-Packet Communications

Nguyen Thi Yen Linh^{*†}, Pham Ngoc Son[†], Vo Nguyen Quoc Bao^{*}

^{*} Posts and Telecommunications Institute of Technology, Vietnam

[†] Ho Chi Minh City University of Technology and Education, Vietnam

Email: linhnty@ptit.edu.vn, linhnty.ncs@hcmute.edu.vn,

baovnq@ptit.edu.vn, sonpndvt@hcmute.edu.vn

Abstract—In this paper, we investigate a non-orthogonal multiple access network supported by both reflecting surfaces and simultaneous transmission (STAR-IRS-NOMA) for short-packet communication. Firstly, the performance metrics of the STAR-IRS-NOMA network, including block error rate (BLER), delay, and throughput for each user, are derived over Rayleigh fading channels. Subsequently, based on Monte Carlo simulations, we verify the accuracy of the derived expressions and demonstrate the superior performance of the STAR-IRS-NOMA system compared to the conventional system (IRS-NOMA). Finally, a deep neural network (DNN) is proposed to predict the delay and throughput of the STAR-IRS-NOMA system. The predictive results provide evidence of the DNN's exceptional advancement in achieving short processing times and high accuracy compared to alternative methods.

Index Terms—Simultaneous transmitting and reflecting, re-configurable intelligent surface, non-orthogonal multiple access, short-packet

I. INTRODUCTION

The Ultra-Reliable Low-Latency Communication (URLLC), the most significant emerging communication scenario in fifth-generation (5G) mobile communication systems, imposes highly stringent requirements on latency (around 1 ms) and reliability (up to 99.9999%) [1]. Consequently, short packet communication (SPC) has become an obligatory replacement for the previously used long packets [2].

Recently, several promising and distinctive technologies have garnered attention for integration into short packet communication systems, such as Non-Orthogonal Multiple Access (NOMA) [3], [4], Simultaneously Transmitting and Reflecting Reconfigurable Intelligent Surface (STAR-IRS), and Deep Learning (DL).

Specifically, a novel enhancement of IRS technology known as Simultaneous Transmit and Reflect (STAR-IRS) has emerged as an immensely significant innovation for next-generation wireless communication networks, due to its capability to elevate signal quality and provide a complete 360° coverage. STAR-IRS also referred to as bi-directional simultaneous transmit and reflect intelligent surface, enables signal penetration through materials via the phenomenon of optical shift [5], [6]. Therefore, applying STAR-IRS to NOMA systems can achieve spatially pervasive coverage

without blind spots, contributing to the efficiency of STAR-IRS-supported NOMA systems, as reported in publications [7]. However, these studies have mainly focused on the STAR-IRS-NOMA system for long packet communication. For SPC, this remains an open topic, with limited literature on STAR-IRS-NOMA in SPC like in [8]. Farjam Karim and colleagues explored the integration of STAR-IRS in a NOMA network for short packet communication in [8]. The results indicate that as the number of STAR-IRS elements increases, the system performance is correspondingly enhanced.

Moreover, recent research has integrated DL into short packet communication systems as in [9] and [10]. Specifically, [9] demonstrates the efficacy of high BLER prediction using DL in a cognitive IoT network system. Authors in [10] investigate DL for predicting the BLER and throughput of a cognitive IoT NOMA network system. The paper exhibits prediction results utilizing DL models with low error rates, short prediction times, and close alignment with simulation results. Inspired by the shared promise and potential benefits of STAR-IRS systems, NOMA networks, and DL for SPC, this paper investigates the performance of a STAR-IRS supported NOMA network for SPC. Moreover, we propose the use of DL to predict system performance, aiming to fulfill real-time requirements of short system execution time for future-generation network systems. Therefore, our primary contributions can be summarized as follows

- Firstly, we derive the approximate expressions for BLER of each user. The overall BLER of the STAR-IRS-NOMA system is also deduced for comparison with the conventional IRS-NOMA system. The results clearly demonstrate the superiority of STAR-IRS-NOMA over IRS-NOMA.
- Next, we compute and analyze the latency and throughput for each user, enabling a more comprehensive assessment of the system's performance. The results demonstrate that latency and throughput decrease as SNR increases, block length decreases.
- Finally, we propose a DNN network based on DL as an effective enhancement method to predict the performance of the proposed network system, meeting the requirements of improved uRLLCs services in future network systems. Prediction results show the superior

enhancements of DNN over simulation and analysis methods in terms of extremely short system execution times.

The remaining part of this paper is structured as follows. In Section II, the system model as well as the channel model and SINR at the users, are elaborated upon in detail. Then, the approximate BLER forms, latency, and throughput for users are analyzed in Section III. Section IV introduces the proposed DNN model for predicting latency and throughput. Next, we analyze simulation results and engage in discussions in Section V. Finally, the conclusion of the paper is provided in Section VI. For the convenience of following the paper, we provide some notations used throughout the entire paper as $\mathbb{C}^{M \times N}$ means the space of vectors with complex values belonging to the field $M \times N$, $CN(\mu, \sigma^2)$ is the circularly symmetric Gaussian distribution with means μ and variance σ^2 , $\text{diag}(\cdot)$ denotes the diagonal matrix, $[\cdot]^T$ denotes the transpose operation, $|\cdot|$ denotes the absolute value, $f_X(\cdot)$ and $F_X(\cdot)$ mean the probability density function (PDF) and cumulative distribution function (CDF) of a random variable X , respectively. $\text{Var}[\cdot]$ and $\mathbb{E}[\cdot]$ denote the variance and the expectation operator, $\Gamma(\cdot)$, $\gamma(\cdot, \cdot)$ and $\Gamma(\cdot, \cdot)$ denote the Gamma function, the upper and lower incomplete Gamma functions.

II. SYSTEM MODEL




Fig. 1. The STAR-IRS system model aided NOMA networks.

As illustrated in Fig. 1, a STAR-IRS aided NOMA downlink network for SPC is considered where a base station (BS) transmits the superposed signals to two users, i.e., one reflecting user $\mathcal{U}_n$ (nearby user) and one transmitting user $\mathcal{U}_f$ (distant user) through NOMA technique.

A STAR-IRS consists $2L$ reflective and refractive elements

operating under mode switching (MS)¹. Specifically, the elements of STAR-IRS are assumed to be divided into two groups: 1) the first group of refractive elements perform in fully transmit mode, and 2) the remaining group performs in fully reflective mode. Furthermore, we assume that over a quasi-static Rayleigh fading channel both the BS and users are equipped with a single antenna each for transmitting and receiving signals. Here, we investigate both the non-direct and direct links between the BS and $\mathcal{U}_n$, denoted as $\omega_0 = \{0, 1\}$. In particular, either $\omega_0 = 0$ or $\omega_0 = 1$ refers to a system without or the existence of a direct link between the BS and $\mathcal{U}_n$. For the distant user, $\mathcal{U}_f$ only receives signals transmitted from the STAR-IRS and ignores the direct transmission path from the BS due to obstacles in the environment. According to the principles of NOMA [12], the BS broadcasts the superimposed signals $x_{BS} = \sum_{i=1}^2 \sqrt{\alpha_i P_{BS}} x_i$, $i \in \{n, f\}$ with the BS transmit power and power allocation factor defined as P_{BS} and α_i , respectively, to the users $\mathcal{U}_i$ through STAR-IRS. Noted that the order of the user priorities is based on the channel gains, where $\mathcal{U}_n$ with stronger channel gain has higher priority compared to $\mathcal{U}_f$ with weaker channel gain. Thus, the power allocation is inversed $\mathcal{U}_n$ and $\mathcal{U}_f$ as $\alpha_f \geq \alpha_n$ and $\alpha_f + \alpha_n = 1$. Then, the received signal at $\mathcal{U}_n$ and $\mathcal{U}_f$ are expressed as

$$y_{\mathcal{U}_n} = \omega_0 h_0 x_{BS} + h_{SI} \Theta_R g_R x_{BS} + n_n, \quad (1)$$

and

$$y_{\mathcal{U}_f} = h_{SI} \Theta_T g_T x_{BS} + n_f, \quad (2)$$

where $n_i, i \in \{n, f\}$, is the complex additive White Gaussian Noise (AWGN) with a mean value of 0 and a variance equal to N_0 at $\mathcal{U}_i$, i.e., statistically denoted by $n_i \sim CN(0, N_0)$ and $\mathbb{E}\{|x_n|^2\} = \mathbb{E}\{|x_f|^2\} = 1$. Let denote the effective cascade channel gains of the transmission links from the BS to STAR-IRS, and STAR-IRS to $\mathcal{U}_i$ can be written as $h_{SI} \Theta_R g_R$ and $h_{SI} \Theta_T g_T$, respectively, in which the reflecting and transmitting coefficient matrices of defined as $\Theta_R = \text{diag}(\sqrt{\beta_1^r} e^{j\phi_1^r}, \sqrt{\beta_2^r} e^{j\phi_2^r}, \dots, \sqrt{\beta_L^r} e^{j\phi_L^r})$ and $\Theta_T = \text{diag}(\sqrt{\beta_1^t} e^{j\phi_1^t}, \sqrt{\beta_2^t} e^{j\phi_2^t}, \dots, \sqrt{\beta_L^t} e^{j\phi_L^t})$. $\sqrt{\beta_\ell^r}, \sqrt{\beta_\ell^t} \in [0, 1]$ and $\phi_\ell^r, \phi_\ell^t \in [0, 2\pi)$ with $\ell = 1, 2, \dots, L$ are the energy coefficient and phase shift of the ℓ -th reflecting and transmitting responses in STAR-IRS. Based on MS protocol [11], the passive element of STAR-IRS operates in complete reflection state (i.e., $\beta_\ell^r = 1$ and $\beta_\ell^t = 0$) while the remaining element operates in complete transmission state (i.e., $\beta_\ell^r = 0$ and $\beta_\ell^t = 1$). Next, channel coefficient of links from the BS to $\mathcal{U}_n$, BS to the ℓ -th of STAR-IRS and from the ℓ -th of STAR-IRS to $\mathcal{U}_i$ are denote by $h_0, h_{SI} = [h_{SI}^1, h_{SI}^2, \dots, h_{SI}^L]^T \in \mathbb{C}^{L \times 1}$, $g_R = [g_R^1, g_R^2, \dots, g_R^L]^T \in \mathbb{C}^{1 \times L}$ and $g_T = [g_T^1, g_T^2, \dots, g_T^L]^T \in \mathbb{C}^{1 \times L}$, respectively.

¹In wireless networks, found on the fundamental signal model of STAR-IRS, there are three main protocols of STAR-IRS as follows: Energy Separation (ES), Mode Switching (MS), and Time Switching (TS). The MS protocol is the easiest to implement compared to the remaining protocols [11]. Now, we only consider the MS mode within STAR-IRS. Our next endeavor will be to extend similar work to the ES and TS protocols

Because the channel coefficients experiences small-scale fading, the channel model as $h_0 \sim CN(0, 1/\lambda_{SU_n})$, $h_{SI} \sim CN(0, 1/\lambda_{SI})$, $g_R \sim CN(0, 1/\lambda_{IU_n})$ and $g_T \sim CN(0, 1/\lambda_{IU_f})$, respectively. The parameters are defined as $\lambda_{SU_n} = d_{SU_n}^\nu$, $\lambda_{SI} = d_{SI}^\nu$, $\lambda_{IU_n} = d_{IU_n}^\nu$, and $\lambda_{IU_f} = d_{IU_f}^\nu$, $\lambda_{SU_n} = d_{SU_n}^\nu$, $\lambda_{SI} = d_{SI}^\nu$, $\lambda_{IU_n} = d_{IU_n}^\nu$, and $\lambda_{IU_f} = d_{IU_f}^\nu$ with the distances of the links from the BS to $\mathcal{U}_n$, the BS to STAR-IRS, STAR-IRS to $\mathcal{U}_n$ and STAR-IRS to $\mathcal{U}_f$ and the small-scale path loss factor of ν , respectively. Furthermore, perfect channel state information (CSI) is assumed for all devices within the system².

For $\mathcal{U}_n$, the successive interference cancellation is performed first, i.e., $\mathcal{U}_n$ will detect the expected signal for $\mathcal{U}_f$, x_f , while its own signal x_n considered noise. Therefore, the SINR expressions of $\mathcal{U}_n$ is presented as

$$\gamma_{\mathcal{U}_n}^{x_f} = \frac{|\omega_0 h_0 + h_{SI} \Theta_{RG_R}|^2 \bar{\gamma} \alpha_f}{|\omega_0 h_0 + h_{SI} \Theta_{RG_R}|^2 \bar{\gamma} \alpha_n + 1}, \quad (3)$$

and

$$\gamma_{\mathcal{U}_n}^{x_n} = |\omega_0 h_0 + h_{SI} \Theta_{RG_R}|^2 \bar{\gamma} \alpha_n, \quad (4)$$

where $\bar{\gamma} = \frac{P_{BS}}{N_0}$ is the transmit SNR. Simultaneously, $\mathcal{U}_n$ decodes its message beforehand, and the signal x_n from $\mathcal{U}_n$ is considered as interference with the SINR as follows:

$$\gamma_{\mathcal{U}_f} = \frac{|h_{SI} \Theta_{TG_T}|^2 \alpha_f \bar{\gamma}}{|h_{SI} \Theta_{TG_T}|^2 \alpha_n \bar{\gamma} + 1}. \quad (5)$$

III. PERFORMANCE ANALYSIS

A. Channel statistics

In this section, we first provided channel statistics for STAR-RIS-aided links. Then, we also obtain the CDF of SINR at the users $\mathcal{U}_i$, $i = \{n, f\}$. Firstly, we also assume that all channel coefficients between nodes in the system are independent identically distributed (i.i.d.) Rayleigh Fading channels. Let $\mathcal{A} = |h_{SI} \Theta_{RG_R}|$ and $\mathcal{T} = \omega_0 h_0 + \mathcal{A}$ denote random variables (RVs). We see that $\mathcal{T}$ follows the Gamma distribution with the shape and scale parameters ς and Ω , i.e., $\mathcal{T} \sim \Gamma(\varsigma, \Omega)$. Based on [13, Lemma 4], the parameters are defined as

$$\varsigma = \frac{(\mathbb{E}[\mathcal{T}])^2}{\text{Var}[\mathcal{T}]}, \quad (6)$$

and

$$\Omega = \frac{\text{Var}[\mathcal{T}]}{\mathbb{E}[\mathcal{T}]}, \quad (7)$$

where

$$\text{Var}[\mathcal{T}] = \left(1 - \frac{\pi}{4}\right) \frac{\omega_0^2}{\lambda_{SU_n}} + \frac{L\beta^r}{\lambda_{SI}\lambda_{IU_n}} \left(1 - \frac{\pi^2}{16}\right). \quad (8)$$

²For conventional IRS-assisted wireless networks, CSI can be obtained through various efficient channel estimation methods as demonstrated in [11]. In the case of the STAR-IRS system, these channel estimation techniques can still be applied to the MS protocol. However, obtaining simultaneous CSI for users across the ES and MS protocols poses an intriguing subject for our future work

$$\mathbb{E}[\mathcal{T}] = \frac{\omega_0}{2} \sqrt{\frac{\pi}{\lambda_{SU_n}}} + \frac{L\pi\sqrt{\beta^r}}{4} \sqrt{\frac{1}{\lambda_{SI}\lambda_{IU_n}}}. \quad (9)$$

Accordingly with [14, Remark 1], $\mathcal{T}^2$ is approximated as the Generalized Gamma distribution (GG) with scale parameter Ω^2 , first shape parameter $\varsigma/2$, second shape parameter $1/2$, i.e., $\mathcal{T}^2 \sim GG(x, \Omega^2, \varsigma/2, 1/2)$. The CDF of $\mathcal{T}^2$ are given by

$$F_{\mathcal{T}^2}(x) = \frac{\gamma(\varsigma, (x/\Omega^2)^{1/2})}{\Gamma(\varsigma)} = 1 - \frac{\Gamma(\varsigma, (x/\Omega^2)^{1/2})}{\Gamma(\varsigma)}. \quad (10)$$

Next, let us define $\mathcal{D} = |h_{SI} \Theta_{TG_T}|$. Noted that $\mathcal{D}^2 \sim \Gamma(\eta, \mu)$ [13, Lemma 1]. The CDF of $\mathcal{D}^2$ is written as

$$F_{\mathcal{D}^2}(x) = \frac{\gamma(\eta, \frac{x}{\mu})}{\Gamma(\eta)} = 1 - \frac{\Gamma(\eta, \frac{x}{\mu})}{\Gamma(\eta)}, \quad (11)$$

where

$$\eta = \frac{L\pi^2\sqrt{\beta^t}}{16 - \pi^2}. \quad (12)$$

$$\mu = \left(\frac{16 - \pi^2}{4\pi}\right) \sqrt{\frac{\beta^t}{\lambda_{SI}\lambda_{IU_f}}}. \quad (13)$$

Next, according to [15, Eq.(4.1)], the CDF of $\gamma_{\mathcal{U}_i}^{x_i}$, $i = \{n, f\}$, is calculated as follows:

$$F_{\gamma_{\mathcal{U}_i}^{x_i}}(x) = \Pr(\gamma_{\mathcal{U}_i}^{x_i} < x). \quad (14)$$

By replacing (3), (4) and (5) into (14) we obtain as

$$F_{\gamma_{\mathcal{U}_n}^{x_f}}(x) = \Pr\left(\frac{|\omega_0 h_0 + h_{SI} \Theta_{RG_R}|^2 \bar{\gamma} \alpha_f}{|\omega_0 h_0 + h_{SI} \Theta_{RG_R}|^2 \bar{\gamma} \alpha_n + 1} < x\right) = \begin{cases} 1, & x \geq \frac{\alpha_f}{\alpha_n}, \\ F_{\mathcal{T}^2}\left(\frac{Z_x}{\bar{\gamma}}\right), & x < \frac{\alpha_f}{\alpha_n}. \end{cases} \quad (15)$$

$$F_{\gamma_{\mathcal{U}_n}^{x_n}}(x) = \begin{cases} 1, & x \geq \frac{\alpha_f}{\alpha_n}, \\ F_{\mathcal{T}^2}\left(\frac{x}{\bar{\gamma} \alpha_n}\right), & x < \frac{\alpha_f}{\alpha_n}. \end{cases} \quad (16)$$

and

$$F_{\gamma_{\mathcal{U}_f}}(x) = \begin{cases} 1, & x \geq \frac{\alpha_f}{\alpha_n}, \\ F_{\mathcal{D}^2}\left(\frac{Z_x}{\bar{\gamma}}\right), & x < \frac{\alpha_f}{\alpha_n}, \end{cases} \quad (17)$$

where $Z_x = \frac{x}{\alpha_f - \alpha_n x}$

B. BLER

We assumed that a given finite block-length (FBL) $\mathcal{K}$ channel uses (≥ 100 CU), BLER $\bar{\epsilon}_j^{\mathcal{X}}$, $j = \{\mathcal{U}_n, \mathcal{U}_f\}$, and Shannon capacity $C(\gamma_j^{\mathcal{X}})$, the maximum achievable channel coding rate can be approximated as [16, Eq.(59)]:

$$\mathcal{R}_j^{\mathcal{X}} = C(\gamma_j^{\mathcal{X}}) - \sqrt{\mathbb{V}(\gamma_j^{\mathcal{X}})/\mathcal{K}Q^{-1}(\epsilon_j^{\mathcal{X}})}, \quad (18)$$

$$(19)$$

where $\chi \in \{x_n, x_f\}$ denotes one type of the intended signal for $\mathcal{U}_i$, $C(\gamma_j^{\mathcal{X}}) = \log_2(1 + \gamma_j^{\mathcal{X}})$, $\mathbb{V}(\gamma_j^{\mathcal{X}}) \triangleq$

$\left(1 - \frac{1}{(1+\gamma_j^x)^2}\right) (\log_2 e)^2$ is the channel dispersion, Q^{-1} is the inverse function of Q-function [17]. Based on (19), the average BLER can be calculated as

$$\bar{\varepsilon}_j^x = \mathbb{E} \left\{ Q \left(\frac{C(\gamma_j^x) - \mathcal{R}_j^x}{\sqrt{V(\gamma_j^x)/K}} \right) \right\}, \quad (20)$$

$$(21)$$

where $\mathcal{R}_j = \frac{\xi_j}{K}$, ξ_j is the information bits to $\mathcal{U}_i$. By utilizing the tight approximation of the Q-function [18], $\bar{\varepsilon}_j^x$ yields

$$\bar{\varepsilon}_j^x = \vartheta_j \sqrt{K} \int_{\Psi_{jL}}^{\Psi_{jH}} F_{\gamma_j^x}(\gamma) d\gamma, \quad (22)$$

$$(23)$$

where $\vartheta_j = [2\pi(2^{2\mathcal{R}_j} - 1)]^{-1/2}$, $\theta_j \triangleq 2^{\mathcal{R}_j} - 1$, $\Psi_{jH} = \theta_j + \frac{1}{2\vartheta_j\sqrt{K}}$ and $\Psi_{jL} = \theta_j - \frac{1}{2\vartheta_j\sqrt{K}}$.

As proven to have high precision in [19], we employ the first-order Riemann approximation method, as the average BLER at $\mathcal{U}_j^x$ can be rewritten as

$$\bar{\varepsilon}_j^x \simeq F_{\gamma_j^x}(\theta_j). \quad (24)$$

By replacing (15), (16) and (17) into (24), we obtain the average BLER at $\mathcal{U}_j^x$ as

$$\bar{\varepsilon}_{\mathcal{U}_n}^{x_f} = \begin{cases} 1, & \theta_{\mathcal{U}_n} \geq \frac{\alpha_f}{\alpha_n}, \\ 1 - \frac{\Gamma\left(\varsigma, \left(\frac{\theta_{\mathcal{U}_n}}{\alpha_f - \alpha_n \theta_{\mathcal{U}_n}}\right)^{1/2}\right)}{\Gamma(\varsigma)}, & \theta_{\mathcal{U}_n} < \frac{\alpha_f}{\alpha_n}. \end{cases} \quad (25)$$

$$\bar{\varepsilon}_{\mathcal{U}_n}^{x_n} = \begin{cases} 1, & \theta_{\mathcal{U}_n} \geq \frac{\alpha_f}{\alpha_n}, \\ 1 - \frac{\Gamma\left(\varsigma, \left(\frac{\theta_{\mathcal{U}_n}}{\alpha_f - \alpha_n \theta_{\mathcal{U}_n}}\right)^{1/2}\right)}{\Gamma(\varsigma)}, & \theta_{\mathcal{U}_n} < \frac{\alpha_f}{\alpha_n}. \end{cases} \quad (26)$$

and

$$\bar{\varepsilon}_{\mathcal{U}_f} = \begin{cases} 1, & \theta_{\mathcal{U}_f} \geq \frac{\alpha_f}{\alpha_n}, \\ 1 - \frac{\Gamma\left(\eta, \frac{1}{\mu} \sqrt{\frac{\theta_{\mathcal{U}_f}}{\alpha_f - \alpha_n \theta_{\mathcal{U}_f}}}\right)}{\Gamma(\eta)}, & \theta_{\mathcal{U}_f} < \frac{\alpha_f}{\alpha_n}. \end{cases} \quad (27)$$

Typically, the approximate expression for the average e2e BLER of the STAR-IRS-NOMA network can be formulated as follows:

$$\bar{\varepsilon}_{NOMA}^{STAR-IRS} = 1 - (1 - \bar{\varepsilon}_{\mathcal{U}_n}) (1 - \bar{\varepsilon}_{\mathcal{U}_f}), \quad (28)$$

where $\bar{\varepsilon}_{\mathcal{U}_n} = \bar{\varepsilon}_{\mathcal{U}_n}^{x_f} + (1 - \bar{\varepsilon}_{\mathcal{U}_n}^{x_f}) \bar{\varepsilon}_{\mathcal{U}_n}^{x_n}$.

Next, the system throughput δ_j is understood as the practical payload of data transmitted across a network within a temporal unit, gauged in n bits per transmission time unit




Fig. 2. Architecture of the DNN model.

(BPCU) [20], [21]. In the IBL, the throughput of user j can be calculated as follows:

$$\delta_j = (1 - \bar{\varepsilon}_j) \mathcal{R}_j. \quad (29)$$

Finally, the system latency is defined as the duration encompassing the transmission and decoding of requisite data from source to destination, quantified by the number of channel usages, as presented by [21]

$$\tau_j = \frac{K}{1 - \bar{\varepsilon}_j}. \quad (30)$$

IV. DEEP-LEARNING APPLICATION

A typical DNN model includes of an input layer, $(Z - 1)$ hidden layers, and an output layer, as represented in Fig. 2. The related variables comprise of the BLER of $\mathcal{U}_i$, $i = \{n, f\}$, with $\bar{\varepsilon}_j \in [10^{-8}, 10^{-3}]$, the blocklength with $K \in [500, 2000]$, A number of bits information with $\xi_i \in [128, 512]$, are practiced as input variables of DNN. The output of DNN corresponds to the system latency and throughput for $\mathcal{U}_i$, which is generated based on (29) and (30), respectively. Each hidden layer contains $Q^{(z-1)}$ neurons with $z = 1, \dots, Z$, and uses Sigmoid activation function to return the predicted output for every input parameter. Next, the DNN framework is divided equally two phases which first is the training phase, and second is the prediction phase. In the training phase, the dataset is utilized for training and processed through an offline procedure, in which the Levenberg-Marquardt optimization algorithm is employed to optimize model parameters based on the dataset [22].

Furthermore, the input variables such as $\bar{\varepsilon}_j$, information bits ξ_i , and BL K at $\mathcal{U}_i$, and the output variables such as throughput δ_j and delay τ_j , are generated for the training dataset $\mathcal{M}$. Generally, in the achieved dataset $\mathcal{M}$, each pattern k is paired as a row vector with $[I_{[k]}, O_{[k]}]$, $k = 1, \dots, \mathcal{M}$, where $I_{[k]} = [\bar{\varepsilon}_j, K, \xi_i]^T$ and $O_{[k]} = [\tau_j, \delta_j]^T$. As a result, $\mathcal{M}$ is generated with 5.10^3 samples, in which 70% is used for the training set $\mathcal{M}_{train}$ and the remainder is utilized for the test set for checking $\mathcal{M}_{test}$, respectively.

V. SIMULATION RESULTS

Firstly, we establish the parameters for the simulation used consistently throughout this article unless stated otherwise as




Fig. 3. The comparison BLER of STAR-IRS-NOMA with IRS-NOMA versus $\bar{\gamma}$.

$\nu = 2$, $N_0 = 1$, $\xi_n = 256$ bits, $\xi_f = 200$ bits, $\alpha_n = 0.3$ and $\alpha_f = 0.7$, $\mathcal{K} = 512$ CUs, $d_{SI} = d_{IU_f} = 10$ m, $d_{SU_n} = 8$ m and $d_{IU_n} = 6$ m [23], and Monte Carlo simulation iterations of 10^5 , respectively. For setting DNN simulation, we use the training parameters as learning rate of 10^{-3} , a number of hidden layers of 5 layers, a number of neuron in the hidden layers of 100 neurons, epoch of 1000 epochs for training phase. The experiments are carried out in a PC with 12th Gen Intel(R) 1255U-core, 16384MB RAM, Iris(R) Xe Graphics, NVIDIA GeForce MX570 and Matlab 2022.

First, Fig. 3 compares the e2e BLER versus $\bar{\gamma}$ of the SPC in the STAR-IRS-NOMA network with other SPC scenarios such as IRS-NOMA. As observed in Fig. 3, it is evident that the performance of the STAR-IRS-NOMA system outperforms the conventional IRS-NOMA system at medium and high $\bar{\gamma}$ values. Noted that in the IRS-NOMA system, the far user is supported by IRS, and the simulation parameters are similar to the STAR-IRS system. Regarding to STAR-IRS in both cases $\omega = \{0, 1\}$, corresponds to the situation in which there is an absence of, or the presence of a direct link from the source to $\mathcal{U}_n$, we find that the performance of STAR-IRS-NOMA in case $\omega = 1$ consistently demonstrates enhancement over case $\omega = 0$ with $\bar{\gamma} \geq 10$ dB.

Next, Fig. 4 compares the latency and throughput between $\mathcal{U}_n$ and $\mathcal{U}_f$ when $\bar{\gamma}$ varies from 10 dB to 20 dB.

As demonstrated, when the values of $\mathcal{K}$ and $\bar{\gamma}$ increase, the BLER significantly decreases. Since latency and throughput are directly influenced by BLER, the impact of $\mathcal{K}$ on these performance metrics is similar to that of BLER. As observed in Fig. 4, we can affirm that the latency and throughput of $\mathcal{U}_n$ and $\mathcal{U}_f$ improve as $\bar{\gamma}$ increases. Specifically, in Fig. 4a, because the BLER of $\mathcal{U}_f$ is lower than the BLER of $\mathcal{U}_n$, $\mathcal{U}_f$ has lower latency than $\mathcal{U}_n$ at $\mathcal{K} = 500$ CUs and $\bar{\gamma} = 10$ dB. When $\mathcal{K}$ ranges from 500 to 600 CUs, the BLER for both $\mathcal{U}_f$ and $\mathcal{U}_n$ decrease rapidly ($\text{BLER} \leq 10^{-5}$), leading to a corresponding reduction in latency.

Especially, at $\bar{\gamma} = 20$ dB and for a large range of $\mathcal{K}$ ($\mathcal{K} \geq 800$ CUs), latency increases almost linearly with $\mathcal{K}$. This




Fig. 4. The comparison of the latency and throughput of STAR-IRS-NOMA for $\mathcal{U}_i$ versus $\mathcal{K}$, where $\alpha_{U_f} = 0.655$, $\bar{\gamma} = 10$ dB and $\bar{\gamma} = 20$ dB, respectively.

can be understood as the BLER at $\mathcal{U}_i$ with $i = \{n, f\}$ being very low (considered $\text{BLER} \leq 10^{-4}$), which is consistent with (30).

By observing Fig. 4b, the throughput of $\mathcal{U}_f$ is consistently lower than that of $\mathcal{U}_n$ for all values of $\bar{\gamma}$. When $\bar{\gamma}$ increases, the BLER at $\mathcal{U}_i$ becomes very low ($\text{BLER} \leq 10^{-4}$). Therefore, throughput depends on the amount of information bits to be transmitted to $\mathcal{U}_i$ and the value of $\mathcal{K}$. However, in this case, we consider that the amount of information bits transmitted to $\mathcal{U}_f$ is lower than the amount of information bits transmitted to $\mathcal{U}_n$. This is entirely consistent with the theoretical result in (29). Furthermore, Fig. 4 demonstrates that the predicted results of latency and throughput at perfectly match the theoretical and simulation results. This indicates the effectiveness of the predicted results from the DNN model. Moreover, compared to theoretical and simulation analysis, the real-time execution time of the DNN-based method is very short (e.g., 0.059589 (s) at $\mathcal{U}_f$ and 0.011744 (s) at $\mathcal{U}_n$ while 49.768579 (s) and 0.128211 (s) for simulation and analysis at $\mathcal{U}_f$; 50.585247 (s) and 0.167550 (s) for simulation and analysis at $\mathcal{U}_n$, respectively). Therefore, for next-generation network systems like 5G and future generations, which require high reliability and short system execution time, the DNN-based prediction method is an efficient approach.

VI. CONCLUSIONS

In this article, we investigate SPCs in a NOMA network supported by STAR-IRS, which is suitable for network systems with limited transmit power and narrow frequency bands to meet URLLCs requirements. First, the approximate expressions for BLER, the latency and throughput of users are also derived. Furthermore, we establish the dominance of the STAR-IRS-NOMA system over conventional IRS-NOMA systems with the same power allocation. Finally, we propose a DNN for jointly estimating the latency and throughput of the STAR-IRS-NOMA system, aiming to

fulfill the extremely short real-time execution requirements of future-generation network systems.

ACKNOWLEDGMENT

This research is supported by Posts and Telecommunications Institute of Technology under grant number 05-2023-HV-CB2.

REFERENCES

- [1] M. Shirvanimoghaddam, M. S. Mohammadi, R. Abbas, A. Minja, C. Yue, B. Matuz, G. Han, Z. Lin, W. Liu, Y. Li *et al.*, "Short block-length codes for ultra-reliable low latency communications," *IEEE Communications Magazine*, vol. 57, no. 2, pp. 130–137, Feb. 2018.
- [2] C. Han, Y. Wu, Z. Chen, and X. Wang, "Terahertz communications (teracom): Challenges and impact on 6g wireless systems," *arXiv preprint arXiv:1912.06040*, Dec. 2019.
- [3] S. S. Sefati and S. Halunga, "Ultra-reliability and low-latency communications on the internet of things based on 5g network: Literature review, classification, and future research view," *Transactions on Emerging Telecommunications Technologies*, vol. 34, no. 6, p. e4770, Apr. 2023.
- [4] N. I. Miridakis, E. T. Michailidis, A. Michalas, E. Skondras, D. J. Vergados, and D. D. Vergados, "Performance of uplink noma with user mobility under short packet transmission," *Wireless Personal Communications*, vol. 122, no. 3, pp. 2273–2283, Aug. 2022.
- [5] A. Patri, G. Lavigne, and C. Caloz, "Metasurface particle with independent transmission and reflection full phase coverage," in *Patri, Ashutosh and Lavigne, Guillaume and Caloz, Christophe*, 2018, pp. 995–996.
- [6] V. Asadchy, M. Albooyeh, S. Tcvtkova, Y. Ra'di, and S. Tretyakov, "Metasurfaces for perfect and full control of refraction and reflection," in *2016 10th International Congress on Advanced Electromagnetic Materials in Microwaves and Optics (METAMATERIALS)*. IEEE, 2016, pp. 364–366.
- [7] B. Zhao, C. Zhang, W. Yi, and Y. Liu, "Ergodic rate analysis of star-ris aided noma systems," *IEEE Communications Letters*, vol. 26, no. 10, pp. 2297–2301, Jul. 2022.
- [8] F. Karim, S. K. Singh, K. Singh, S. Prakriya, and M. F. Flanagan, "On the performance of star-ris-aided noma at finite blocklength," *IEEE Wireless Communications Letters*, vol. 12, no. 5, pp. 868 – 872, Feb. 2023.
- [9] C. D. Ho, T.-V. Nguyen, T. Huynh-The, T.-T. Nguyen, D. B. da Costa, and B. An, "Short-packet communications in wireless-powered cognitive iot networks: Performance analysis and deep learning evaluation," *IEEE Transactions on Vehicular Technology*, vol. 70, no. 3, pp. 2894–2899, Feb. 2021.
- [10] T.-H. Vu, T.-V. Nguyen, T.-T. Nguyen, and S. Kim, "Performance analysis and deep learning design of wireless powered cognitive noma iot short-packet communications with imperfect csi and sic," *IEEE Internet of Things Journal*, vol. 9, no. 13, pp. 10464 – 10479, Oct. 2021.
- [11] X. Mu, Y. Liu, L. Guo, J. Lin, and R. Schober, "Simultaneously transmitting and reflecting (star) ris aided wireless communications," *IEEE Transactions on Wireless Communications*, vol. 21, no. 35, pp. 3083–3098, Oct. 2021.
- [12] Z. Ding, M. Peng, and H. V. Poor, "Cooperative non-orthogonal multiple access in 5g systems," *IEEE Communications Letters*, vol. 19, no. 8, pp. 1462–1465, Jun. 2015.
- [13] H. Ren, K. Wang, and C. Pan, "Intelligent reflecting surface-aided urlrc in a factory automation scenario," *IEEE Transactions on Communications*, vol. 70, no. 1, pp. 707–723, Nov. 2021.
- [14] T. N. Do, G. Kaddoum, T. L. Nguyen, D. B. Da Costa, and Z. J. Haas, "Multi-ris-aided wireless systems: Statistical characterization and performance analysis," *IEEE Transactions on Communications*, vol. 69, no. 12, pp. 8641–8658, Oct. 2021.
- [15] A. Papoulis and S. Unnikrishna Pillai, *Probability, random variables and stochastic processes*, 2002.
- [16] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multiple-antenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, pp. 4232–4265, Apr. 2014.
- [17] O. L. A. López, E. M. G. Fernández, R. D. Souza, and H. Alves, "Ultra-reliable cooperative short-packet communications with wireless energy transfer," *IEEE Sensors Journal*, vol. 18, no. 5, pp. 2161–2177, Jan. 2018.
- [18] B. Makki, T. Svensson, and M. Zorzi, "Finite block-length analysis of the incremental redundancy harq," *IEEE Wireless Communications Letters*, vol. 3, no. 5, pp. 529–532, Aug. 2014.
- [19] N. T. Y. Linh, N. H. Tu, P. N. Son, and V. N. Q. Bao, "Dual-hop relaying networks for short-packet urlrcs: Performance analysis and optimization," *Journal of Communications and Networks*, vol. 24, no. 4, pp. 408–418, Aug. 2022.
- [20] O. L. A. López, R. D. Souza, H. Alves, and E. M. G. Fernández, "Ultra reliable short message relaying with wireless power transfer," in *2017 IEEE International Conference on Communications (ICC)*. IEEE, 2017, pp. 1–6.
- [21] R. Devassy, G. Durisi, P. Popovski, and E. G. Ström, "Finite-blocklength analysis of the arq-protocol throughput over the gaussian collision channel," in *2014 6th International Symposium on Communications, Control and Signal Processing (ISCCSP)*. IEEE, 2014, pp. 173–177.
- [22] A. Reynaldi, S. Lukas, and H. Margaretha, "Backpropagation and levenberg-marquardt algorithm for training finite element neural network," in *2012 Sixth UKSim/AMSS European Symposium on Computer Modeling and Simulation*. IEEE, 2012, pp. 89–94.
- [23] X. Yue, J. Xie, Y. Liu, Z. Han, R. Liu, and Z. Ding, "Simultaneously transmitting and reflecting reconfigurable intelligent surface assisted noma networks," *IEEE Transactions on Wireless Communications*, vol. 22, no. 1, pp. 189–204, Aug. 2022.

Power allocation for the STAR-RIS-NOMA Short Packet communication system using Deep Reinforcement Learning

Nguyen Thi Yen Linh^{*†}, Pham Ngoc Son[†], Vo Nguyen Quoc Bao[‡]

^{*} Posts and Telecommunications Institute of Technology, Vietnam

[†] Ho Chi Minh City University of Technology and Education, Vietnam

[‡] Van Lang School of Technology, Van Lang University, Vietnam

Email: linhnty@ptit.edu.vn, linhnty.ncs@hcmute.edu.vn,

sonpndvt@hcmute.edu.vn, bao.vnq@vlu.edu.vn

Abstract—Optimizing power is crucial for modern intelligent communication systems. This paper explores power allocation in short-packet networks using Non-Orthogonal Multiple Access (NOMA) and Simultaneously Transmitting and Reflecting Reconfigurable Intelligent Surface (STAR-RIS) technology. STAR-RIS enhances coverage, saves energy, and improves signal transmission to users on both sides of the source. We propose using Deep Reinforcement Learning (DRL) with the Proximal Policy Optimization (PPO) algorithm to optimize transmission power and power allocation coefficients. PPO directly optimizes the agent's policy, using channel state information as input and producing transmission power values and power allocation coefficients as output. Numerical results show that DRL reduces computational complexity and requires minimal training data and time.

Index Terms—Simultaneous transmitting and reflecting reconfigurable intelligent surface, non-orthogonal multiple access, short-packet, deep reinforcement learning

I. INTRODUCTION

The rapid advancement of the Internet of Things (IoT) and massive machine-type communications (mMTC) has significantly increased the demand for higher data rates, enhanced reliability, lower latency, and efficient bandwidth utilization in beyond Fifth Generation (5G) and Sixth Generation (6G) networks [1]. Short Packet Communications (SPC) have emerged as a crucial method to support these new network systems [2]. Recently, integrating SPC with technologies such as Non-Orthogonal Multiple Access (NOMA), Simultaneously Transmitting And Reflecting Reconfigurable Intelligent Surfaces (STAR-RIS) with NOMA, and Deep Reinforcement Learning (DRL) has become a promising research direction for intelligent applications in

future wireless networks. The pioneering work in [3] examined downlink SPC-NOMA networks with randomly distributed users in Nakagami-m fading channels, evaluating performance using average BLER. Building on this, [4] investigated downlink NOMA networks with a multi-antenna source serving two single-antenna users (one near, one far) aided by RIS, achieving lower BLER for the far user and employing Deep Neural Networks (DNN) for power allocation prediction.

Despite RIS's performance and cost advantages, its 180° coverage is inadequate for new network systems. STAR-RIS technology extends coverage to 360° by reflecting and refracting signals. Studies [5] and [6] show that STAR-RIS-NOMA networks surpass traditional RIS-NOMA in BLER, latency, and throughput. Deep learning (DL) is in its early stages for 5G but is expected to significantly enhance 6G communications by improving multi-connectivity, data rates, and latency. Challenges persist in meeting reliability and real-time data requirements for industrial automation. Despite advancements like DNN-based power optimization in RIS-NOMA systems [4], [5], traditional numerical methods struggle with non-convex functions, computational complexity, and the need for extensive training datasets.

In this context, DRL is proposed for dynamic wireless communication optimization. DRL effectively addresses blocklength allocation and power control in URLLC systems and subcarrier power control in IoT networks [7], [8]. Our paper designs a STAR-RIS-NOMA-SPC system using DRL to

optimize power allocation, addressing gaps in previous research. The main contributions of this paper are summarized as follows:

- Firstly, we develop a downlink SPC-NOMA system using STAR-RIS to achieve comprehensive coverage for all users within the spatial domain surrounding the source. We establish user data transmission rates and introduce an optimization problem for source and user power allocation, aiming to maximize data rates within power constraints.
- Then, we propose an innovative DRL-based solution for optimal power allocation in the STAR-RIS-NOMA-SPC system. In this framework, the source acts as an agent, interacting with the environment and making optimal power decisions to maximize transmission rates at each iteration.
- Lastly, we demonstrate the DRL method's effectiveness in mitigating computational complexity, addressing non-convex challenges, reducing simulation time, and eliminating the need for extensive training datasets. These advantages are validated by MATLAB simulation results, resolving the optimal power allocation problem for STAR-RIS-NOMA-SPC systems.

The paper is structured as follows: Section II introduces the system model and problem formulation. Section III covers the DRL model and PPO algorithm. Section IV presents simulation results, and Section V concludes the paper.

For clarity, the following notations are used: $\mathbb{C}^{M \times N}$ denotes the space of $M \times N$ complex-valued vectors, $\mathcal{CN}(\mu, \sigma^2)$ represents the circularly symmetric Gaussian distribution with mean μ and variance σ^2 , $\text{diag}(\cdot)$ indicates a diagonal matrix, $[\cdot]^T$ signifies the transpose operation, and $\mathbb{E}[\cdot]$ is the expectation operator.

II. SYSTEM MODEL

A. Channel model

We investigate a STAR-RIS-assisted NOMA downlink network for SPC, similar to the system model in [5]. In this network, a base station (BS) uses NOMA to transmit combined signals to two users: a reflecting user ($\mathcal{U}_R$) and a transmitting user ($\mathcal{U}_T$). The STAR-RIS, featuring $2L$ reflective and refractive elements, operates under the simpler mode switching (MS) protocol [9]. Both the BS

and users have single antennas, transmitting and receiving signals through a quasi-static Rayleigh fading channel¹. The reflecting user $\mathcal{U}_R$, on the same side as the BS, receives both reflected and direct signals, while the transmitting user $\mathcal{U}_T$ receives signals only from the STAR-RIS, with direct signals blocked by obstacles. Let the channel coefficients for the links from the BS to $\mathcal{U}_R$, BS to STAR-RIS, and from STAR-RIS to $\mathcal{U}_i$ ($i = \{R, T\}$) be h_0 , $h_{ST} \in \mathbb{C}^{L \times 1}$, $g_R \in \mathbb{C}^{1 \times L}$, and $g_T \in \mathbb{C}^{1 \times L}$, respectively. The channel coefficients, experiencing small-scale fading, are modeled as $h_0 \sim \mathcal{CN}(0, d_{SU_R}^{-\nu})$, $h_{ST} \sim \mathcal{CN}(0, d_{ST}^{-\nu})$, $g_R \sim \mathcal{CN}(0, d_{STU_R}^{-\nu})$ and $g_T \sim \mathcal{CN}(0, d_{STU_T}^{-\nu})$. Here, d_{SU_R} , d_{ST} , and d_{STU_i} represent to the distances from the BS to $\mathcal{U}_R$, BS to STAR-RIS, STAR-RIS to $\mathcal{U}_i$, respectively, with ν being the small-scale path loss factor. Define the diagonal phase-shift matrices of STAR-RIS as $\Theta_R = \text{diag}(\sqrt{\beta_1^r}e^{j\phi_1^r}, \sqrt{\beta_2^r}e^{j\phi_2^r}, \dots, \sqrt{\beta_L^r}e^{j\phi_L^r})$ and $\Theta_T = \text{diag}(\sqrt{\beta_1^t}e^{j\phi_1^t}, \sqrt{\beta_2^t}e^{j\phi_2^t}, \dots, \sqrt{\beta_L^t}e^{j\phi_L^t})$, corresponding to g_R and g_T . Here, $\beta_\ell^r, \beta_\ell^t \in [0, 1]$ and $\phi_\ell^r, \phi_\ell^t \in [0, 2\pi)$ are the energy coefficients and phase shifts for the ℓ -th reflecting and transmitting responses in STAR-RIS, where $\ell = 1, 2, \dots, L$. The system operates in full reflection mode when $\beta_\ell^r = 1$ and $\beta_\ell^t = 0$, and in full transmission mode when $\beta_\ell^t = 1$ and $\beta_\ell^r = 0$. Additionally, perfect channel state information (CSI) is assumed to be available at the BS, with perfect feedback from STAR-RIS². According to NOMA principles, the BS broadcasts the superimposed signals $x_{BS} = \sum_{i=1}^2 \sqrt{\alpha_i P} x_i$, where $i \in \{R, T\}$, with transmit power P , the signal intended x_i , and power allocation factor α_i to the users via STAR-RIS. User priority is based on channel gains, with user $\mathcal{U}_R$ having a stronger channel gain and higher priority than user $\mathcal{U}_T$. Consequently, power allocation is inversely proportional, such that $\alpha_T \geq \alpha_R$ and $\alpha_T + \alpha_R = 1$. The received signals at $\mathcal{U}_R$ and $\mathcal{U}_T$ are expressed as

$$y_{\mathcal{U}_R} = (h_0 + h_{ST}\Theta_R g_R) \times \left(\sqrt{\alpha_R P} x_R + \sqrt{\alpha_T P} x_T \right) + n_R, \quad (1)$$

¹Quasi-static fading channels are characterized by fading coefficients that remain constant within each transmission block but change independently between blocks, representing a practical worst-case scenario.

²Owing to space constraints, perfect CSI is considered suitable. Future work will explore imperfect channel conditions.

and

$$y_{\mathcal{U}_T} = (h_{ST}\Theta_T g_T) \times \left(\sqrt{\alpha_R P} x_R + \sqrt{\alpha_T P} x_T \right) + n_T, \quad (2)$$

where $n_i \sim \mathcal{CN}(0, \sigma^2)$ and $\mathbb{E}[x_i^2] = 1$.

The channel coefficients from the BS to the ℓ -th reflecting element of STAR-RIS, and from this element to $\mathcal{U}_R$ and $\mathcal{U}_T$ are denoted as $h_{ST} = [h_{ST}^1, h_{ST}^2, \dots, h_{ST}^L]^T$, $g_R = [g_R^1, g_R^2, \dots, g_R^L]^T$ and $g_T = [g_T^1, g_T^2, \dots, g_T^L]^T$, respectively. Successive interference cancellation is first performed at $\mathcal{U}_R$. Specifically, $\mathcal{U}_R$ detects the signal x_T intended for $\mathcal{U}_T$ while treating its own signal x_R as noise. Consequently, the Signal-to-Interference-plus-Noise Ratio (SINR) expressions of $\mathcal{U}_R$ are as follows:

$$\gamma_{\mathcal{U}_R}^{x_T} = \frac{|h_0 + h_{ST}\Theta_R g_R|^2 \bar{\gamma} \alpha_T}{|h_0 + h_{ST}\Theta_R g_R|^2 \bar{\gamma} \alpha_R + 1}, \quad (3)$$

and

$$\gamma_{\mathcal{U}_R}^{x_R} = |h_0 + h_{ST}\Theta_R g_R|^2 \bar{\gamma} \alpha_R, \quad (4)$$

where $\bar{\gamma} = \frac{P}{\sigma^2}$ is the transmit signal-to-noise ratio (SNR). Simultaneously, $\mathcal{U}_T$ decodes its information first, treating the signal x_R for $\mathcal{U}_R$ as interference, with SINR given by

$$\gamma_{\mathcal{U}_T} = \frac{|h_{ST}\Theta_T g_T|^2 \alpha_T \bar{\gamma}}{|h_{ST}\Theta_T g_T|^2 \alpha_R \bar{\gamma} + 1}. \quad (5)$$

B. Problem formulation

To evaluate system performance, we consider the achievable data rate. In SPC systems, block length must remain small ($K \geq 100$ CUs) due to latency requirements or the nature of IoT applications. Consequently, for a given BLER and block length, the achievable rate is calculated as follows [10, Eq.(59)]:

$$\mathcal{R}_j = \log_2(1 + \gamma_j) - \sqrt{\left(1 - \frac{1}{(1 + \gamma_j)^2}\right) (\log_2 e)^2 / K Q^{-1}(\bar{\epsilon}_j)}, \quad (6)$$

where $j = \{\mathcal{U}_R, \mathcal{U}_T\}$, Q^{-1} is the inverse function of Q-function [11].

The primary objective of our proposed system is to meet the stringent requirements of URLLCs. This involves determining the optimal transmission

power allocation for the system's source and the appropriate power allocation for users within the system to maximize the achieved decoding rate. Thus, the optimization problem can be formulated as follows:

$$\max_{\{P, \alpha_i\}} \mathcal{R}_j(P, \alpha_i), \quad (7)$$

$$\text{s.t. } 0 < P \leq P_{\max}, \quad (8)$$

$$0 < \alpha_i < 1, \quad (9)$$

where $P_{\max}$ is the maximum transmission power, $P = \alpha_R P + \alpha_T P > 0$, and $0 < \alpha_T \leq 1 - \alpha_R$. Upon examining (7), we find that the decoding rate is a complex function of the average SNR, which depends on the power allocation to both the source BS and network users. This renders the power allocation coefficients unknown. Consequently, solving the optimization problem in (7) with partial derivatives, while ensuring the convexity of the objective function and satisfying the conditions in (8) and (9), is challenging. Therefore, we propose employing a DRL approach to address this optimization problem.

III. DEEP REINFORCEMENT LEARNING APPLICATIONS

A. DRL Framework




Fig. 1. DRL framework for the proposed STAR-RIS-NOMA networks.

DRL combines DNN with Reinforcement Learning (RL) to handle high-dimensional data efficiently and accelerate convergence [12]. It aims to develop a policy for navigating an environment to maximize future rewards. This challenge is formulated as an incompletely known Markov Decision Process (MDP) defined by the tuple $\{\mathcal{S}, \mathcal{A}, \delta, r, \mathcal{P}\}$,

where $\mathcal{S}$ is the state space, $\mathcal{A}$ is the action set, $\delta \in (0, 1)$ is the discount factor, and r and $\mathcal{P}$ represent the reward and transition probability, respectively [13]. We will use this MDP framework to design the agent, action, and reward components for our DRL approach, depicted in Fig. 1.

- **Agent:** In our research, the base station (BS) acts as the agent. At each time step t , the BS observes the state $s^{(t)}$ from the environment, selects an action $a^{(t)}$ based on the current state, and receives a corresponding reward $r^{(t)}$.
- **State space $\mathcal{S}$:** A set of characteristic observations of the environment. The state $s^{(t)} \in \mathcal{S}$ represents the observation at time step t . In the system model, $s^{(t)}$ encompasses channel state information, the transmission power allocated to the base station, and power allocation coefficients for the users. For example, in the case of $\mathcal{U}_T$, the state $s^{(t)}$ is defined as follows:

$$s^{(t)} = \{h_{ST}^{(t)}, g_T^{(t)}, P^{(t)}, \alpha_T^{(t)}\}. \quad (10)$$

- **Action space $\mathcal{A}$:** A set of options. The agent executes an action $a^{(t)}$ at time t for $\mathcal{U}_T$, defined as

$$a^{(t)} = \{P^{(t)}, \alpha_T^{(t)}\}. \quad (11)$$

Within the system, $P \in [0, P_{\max}]$ and $\alpha_T \in [0, 1]$ are continuous variables. When the agent takes action $a^{(t)}$, the environment transitions from state $s^{(t)}$ to the next state $s^{(t+1)}$, resulting in the agent receiving a reward $r^{(t)}$.

- **Reward r :** Return outcome. The objective of the learning model is to maximize the long-term reward. The reward $r^{(t)}$ evaluates the agent's performance in executing action $a^{(t)}$ while observing state $s^{(t)}$ at time t . The reward function in this system is defined as

$$r^{(t)}(s^{(t)}, a^{(t)}) = \begin{cases} \mathcal{R}_j^{(t)} & \text{if satisfy (8), (9),} \\ -1 & \text{otherwise.} \end{cases} \quad (12)$$

- **Transition probability $\mathcal{P}$:** The probability of transitioning from the current state $s^{(t)}$ to the subsequent state $s^{(t+1)}$.

Observation (12) shows that the agent incurs a penalty when constraints (8) and (9) are not satisfied. Therefore, the agent can choose actions to optimize rate performance.

B. Proposed Proximal Policy Optimization Algorithm

Proximal Policy Optimization (PPO), a policy gradient method, is renowned for its simplicity and minimal hyperparameter tuning, particularly suited for applications in wireless networks [14]. PPO adopts an actor-critic architecture, where the actor learns the policy by mapping states to actions, while the critic evaluates these actions by assessing the associated rewards. The PPO algorithm optimizes the policy by utilizing a surrogate objective function with clipping to constrain updates and prevent overly drastic policy changes. The objective is defined as follows:

$$\mathcal{L}_{\theta_k} = \mathbb{E}_{\pi_{\theta_k}} \left[\sum_{t=0}^T \min \left(r^{(t)}(\theta) A_{\pi_k}^{(t)}, \text{clip} \left(r^{(t)}(\theta), 1 - \epsilon, 1 + \epsilon \right) A_{\pi_k}^{(t)} \right) \right], \quad (13)$$

where $r^{(t)}(\theta)$ represents the probability ratio between the new policy π_{θ_k} and the old policy π_{θ} , ensuring stable learning by bounding updates with a hyperparameter ϵ . The advantage function $A_{\pi}^{(t)}$ evaluates how beneficial an action is compared to the expected value, and is calculated as

$$A_{\pi}^{(t)}(s^{(t)}, a^{(t)}) = Q_{\pi}^{(t)}(s^{(t)}, a^{(t)}) - V_{\pi}^{(t)}(s^{(t)}), \quad (14)$$

where $V_{\pi}^{(t)}(s^{(t)})$ is the state-value function, and $Q_{\pi}^{(t)}(s^{(t)}, a^{(t)})$ is the action-value function estimated from samples. To mitigate abrupt policy shifts, the clipping term ensures that updates remain within a controlled range defined by $1 - \epsilon$ and $1 + \epsilon$, maintaining consistency and convergence throughout training.

The PPO algorithm used to address the optimization problem in our system is detailed in **Algorithm 1**. Before each episode, the environment is reset, and essential policy parameters—including the learning rate, discount factor, clipping range, and entropy coefficient—are reinitialized (see step 3). The agent records experience tuples $(s^{(t)}, a^{(t)}, r^{(t)}, s^{(t+1)})$ in replay memory to leverage past interactions for learning (step 6). A mini-batch is then randomly sampled from this memory for training, optimizing computational efficiency by eliminating the need to process the entire dataset (step 7). The advantage

estimate (step 10) refines the policy by differentiating effective actions from ineffective ones, ensuring stable updates.

Algorithm 1: PPO-Based Power Allocation for STAR-RIS-NOMA System

- 1: Initialize hyperparameters: learning rate, sample time, batch size, maximum episodes (N_{epi}), update step (N_{step});
 - 2: **for** Episode = 1 to N_{epi} **do**
 - 3: Initialize the environment and reset policy parameters;
 - 4: **for** Iteration = 1 to N_{step} **do**
 - 5: Input $s^{(t)}$, take $a^{(t)}$, receive $r^{(t)}$ in (12), and observe next state $s^{(t+1)}$.
 - 6: Store $s^{(t)}$, $a^{(t)}$, $r^{(t)}$, and $s^{(t+1)}$ in replay memory;
 - 7: Sample mini-batches from memory;
 - 8: Run policy π_{θ} ;
 - 9: Calculate advantage estimate from (14);
 - 10: Optimize the surrogate objective function $\mathcal{L}_{\theta_k}$ in (13);
 - 11: **end for**
 - 12: **end for**
 - 13: Obtain P and α_i .
-

IV. SIMULATION

This section illustrates PPO algorithm's effectiveness in optimizing power and allocation coefficients within the STAR-RIS-NOMA network's SPC system. Key parameters include $P_{\text{max}} = 30$ dB, $\nu = 2$, $\sigma^2 = 1$, $\mathcal{K} = 512$ CUs, BLER of $\mathcal{U}_j$ ($j \in \{\mathcal{U}_R, \mathcal{U}_T\}$) at 10^{-5} , $L = 16$, and distances $d_{SU_R} = d_{STU_T} = 10$ m, $d_{ST} = 8$ m, and $d_{STU_R} = 6$ m [5]. Training parameters include a learning rate of 0.0001, max episode length of 200, discount factor of 0.9, time-step of 200, batch size of 64, and experience buffer length of 10^4 . The neural networks employ 256 neurons in hidden layers, use ReLU activation, and are optimized with the ADAM algorithm. Simulations were conducted on a system featuring a 12th gen Intel® Core™ i7-12255U processor, 32GB RAM, two Intel® Iris® Xe Graphics cards, an NVIDIA GeForce MX570, and MATLAB 2024.

Fig. 2 compares the average reward performance of the PPO algorithm with the Deep Deterministic




Fig. 2. The convergence and average rewards obtained over iterations for the three algorithms: PPO, DDPG, and TD3.




Fig. 3. Achievable average reward versus various batch sizes, learning rates, and discount factor levels of the PPO algorithm.

Policy Gradient (DDPG) and Twin Delayed Deep Deterministic Policy Gradient (TD3) algorithms. DDPG uses an Actor-Critic method, while PPO employs Policy Gradient for direct updates. TD3, an improved DDPG, mitigates fluctuation and slow convergence issues. Fig. 2 shows that PPO outperforms DDPG and TD3, achieving an average reward of 146.976 bps/CUs after 105 episodes with a training time of about 162 seconds. Although TD3 converges faster than both PPO and DDPG, its average reward is lower, and its training time is longer (over 737.6 seconds), but still shorter than DDPG's (2133.8 seconds). Next, Fig. 3 illustrates the impact of batch size $\mathcal{B}$, learning rate LR, and discount factor δ on the average rewards of the proposed PPO algorithm. Batch size $\mathcal{B}$ represents the number of samples processed before updating

the model's parameters. Fig. 3a shows that the algorithm performs best at $\mathcal{B} = 256$ compared to $\mathcal{B} = 64$ and $\mathcal{B} = 128$. Larger batch sizes provide smoother gradient estimates and more stable updates, while smaller batch sizes result in noisier gradients and higher variance. Therefore, $\mathcal{B} = 256$ is the optimal batch size. Next, the learning rate is a critical parameter controlling the step size at each iteration, as shown in Fig. 3b. The results demonstrate greater efficiency at $\text{LR} = 10^{-2}$ and $\text{LR} = 10^{-3}$ compared to lower rates such as $\text{LR} = 10^{-5}$ and $\text{LR} = 10^{-6}$ due to faster convergence. A very low learning rate can cause the algorithm to become trapped in local minima and extend the training duration. For instance, at $\text{LR} = 10^{-3}$, the training time is 35.04 seconds, whereas at $\text{LR} = 10^{-6}$, the time increases significantly. Therefore, we select $\text{LR} = 10^{-3}$ for future training. The discount factor δ ($\delta \in [0, 1]$) determines the importance of future rewards, as shown in Fig. 3c. Higher values ($\delta = 0.85$ and $\delta = 0.9$) result in higher average rewards by considering long-term benefits compared to $\delta = 0.7$, which prioritizes short-term rewards. Finally, for optimal training parameters of our system model, we use a batch size of 256, a learning rate of 0.0001, a discount factor of 0.9, and $\text{BLER} = 10^{-5}$. The trained agent derives optimal actions corresponding to power values allocated to the system and power allocation factors for $\mathcal{U}_j$. The optimal power value allocated is $P = 25.4$ dB, with allocation factors $\alpha_T = 0.8753$ for $\mathcal{U}_T$ and $\alpha_R = 0.1247$ for $\mathcal{U}_R$.

V. CONCLUSIONS

This paper investigates resource and power allocation strategies to enhance rate performance in STAR-RIS-NOMA short-packet networks under power constraints. We reformulate the optimization problem within a DRL framework, using the source as an agent and leveraging a PPO algorithm for power prediction and allocation. Simulation results demonstrate that our approach surpasses other RL methods in terms of sum-rate performance and convergence time. Future work will explore intelligent systems incorporating multiple antennas and mobile users.

ACKNOWLEDGMENT

This research is supported by Posts and Telecommunications Institute of Technology under grant

number 09-2024-HV-CB2.

REFERENCES

- [1] R. Singh, A. Kaushik, W. Shin, M. Di Renzo, V. Sciancalepore, D. Lee, H. Sasaki, A. Shojaeifard, and O. A. Dobre, "Towards 6g evolution: Three enhancements, three innovations, and three major challenges," *arXiv preprint arXiv:2402.10781*, Feb. 2024.
- [2] G. Durisi, T. Koch, and P. Popovski, "Toward massive, ultrareliable, and low-latency wireless communication with short packets," *Proceedings of the IEEE*, vol. 104, no. 9, pp. 1711–1726, Aug. 2016.
- [3] J. Zheng, Q. Zhang, and J. Qin, "Average block error rate of downlink noma short-packet communication systems in nakagami- m fading channels," *IEEE Communications Letters*, vol. 23, no. 10, pp. 1712–1716, Jul. 2019.
- [4] N. T. Y. Linh, P. N. Son, and V. N. Q. Bao, "Intelligent reflecting surface-assisted beamforming-noma networks for short-packet communications: Performance analysis and deep learning approach," *IET Communications*, vol. 17, no. 16, pp. 1940–1954, Aug. 2023.
- [5] —, "Performance evaluation of simultaneously transmitting and reflecting intelligent reflecting surface-assisted noma networks for short-packet communications," in *2023 RIVF International Conference on Computing and Communication Technologies (RIVF)*. IEEE, 2023, pp. 194–199.
- [6] T.-H. Vu, T.-V. Nguyen, Q.-V. Pham, D. B. da Costa, and S. Kim, "Star-ris-enabled short-packet noma systems," *IEEE Transactions on Vehicular Technology*, vol. 72, no. 10, pp. 13 764–13 769, May. 2023.
- [7] X. Li, X. Zhang, J. Li, F. Luo, Y. Huang, and X. Zhang, "Blocklength allocation and power control in uav-assisted urllc system via multi-agent deep reinforcement learning," *International Journal of Computational Intelligence Systems*, vol. 17, no. 1, p. 138, Jun. 2024.
- [8] H. Wang, X. Li, F. Luo, J. Li, and X. Zhang, "Subcarrier power control for urllc communication system via multi-agent deep reinforcement learning in iot network," *International Journal of Communication Networks and Distributed Systems*, vol. 30, no. 3, pp. 374–392, Apr. 2024.
- [9] X. Mu, Y. Liu, L. Guo, J. Lin, and R. Schober, "Simultaneously transmitting and reflecting (star) ris aided wireless communications," *IEEE Transactions on Wireless Communications*, vol. 21, no. 5, pp. 3083–3098, Oct. 2021.
- [10] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multiple-antenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, pp. 4232–4265, Apr. 2014.
- [11] O. L. A. López, E. M. G. Fernández, R. D. Souza, and H. Alves, "Ultra-reliable cooperative short-packet communications with wireless energy transfer," *IEEE Sensors Journal*, vol. 18, no. 5, pp. 2161–2177, Mar. 2018.
- [12] K. Arulkumaran, M. P. Deisenroth, M. Brundage, and A. A. Bharath, "Deep reinforcement learning: A brief survey," *IEEE Signal Processing Magazine*, vol. 34, no. 6, pp. 26–38, Nov. 2017.
- [13] M. L. Puterman, *Markov decision processes: discrete stochastic dynamic programming*. John Wiley & Sons, 2014.
- [14] J. Schulman, F. Wolski, P. Dhariwal, A. Radford, and O. Klimov, "Proximal policy optimization algorithms," *arXiv preprint arXiv:1707.06347*, Aug. 2017.