

# ƯỚC LƯỢNG XÁC SUẤT DỪNG CỦA MÔ HÌNH CHUYỂN TIẾP HAI CHIỀU Ở KÊNH TRUYỀN FADING RAYLEIGH BẰNG PHƯƠNG PHÁP HỌC SÂU

Nguyễn Hữu Phong\*, Võ Nguyễn Quốc Bảo<sup>+</sup>

\* Trường Đại học Bách khoa TP.HCM

<sup>+</sup> Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở TP.HCM

**Tóm tắt**—Trong bài báo này, chúng tôi đề xuất phương pháp hiệu quả để đánh giá hiệu năng qua tham số xác suất dừng (OP) của sơ đồ truyền thông chuyển tiếp hai chiều (TWRN) dựa trên phương pháp học sâu DL (Deep-learning). Mô hình xem xét bao gồm hai nút nguồn trao đổi thông tin với nhau dưới sự hỗ trợ của nút chuyển tiếp (R) sử dụng kỹ thuật khuếch đại và chuyển tiếp (AF) có thu thập năng lượng (EH). Trước tiên, biểu thức OP dạng tường minh được rút trích. Mô phỏng kiểm chứng Monte-Carlo thực hiện qua kênh fading Rayleigh để xác minh tính chính xác cho biểu thức OP đề xuất. Hơn nữa, chúng tôi sử dụng phương pháp có độ phức tạp thấp để dự đoán OP qua mô hình học sâu. Các kết quả mô phỏng OP trùng khớp với phương pháp dùng DL.

**Từ khóa**— TWRN, EH, DL, OP.

## I. GIỚI THIỆU

Do hiệu quả phổ tần cao hơn so với chuyển tiếp một chiều, truyền thông chuyển tiếp hai chiều (TWRN) nhận được sự quan tâm đáng kể vào những năm gần đây [1]. Xét một mạng TWRN cụ thể, thông tin của hai nút nguồn trao đổi qua lại với sự hỗ trợ của một hoặc nhiều nút chuyển tiếp (R) ở giữa. Các giao thức chuyển tiếp đáng tin cậy đã được phát triển để sử dụng những ưu điểm của TWRN [2]. Hiệu năng của mạng TWRN đã được đánh giá trong các nghiên cứu [3–4]. Đặc biệt, xác suất dừng (OP) đã được phân tích trong [5–6].

Học máy (ML) là một lĩnh vực đã phát triển rộng rãi trong các công nghệ hiện đại. Công nghệ này đã được tích hợp với nhiều lĩnh vực khác nhau như bảo mật, xử lý tín hiệu và hình ảnh, và mạng truyền thông không dây [7–9]. Phân tích OP của sơ đồ đa truy cập không trực giao (NOMA) sử dụng vừa truyền thông tin vừa truyền năng lượng (SWIPT) dựa trên mô hình học sâu (DL) đã được nghiên cứu trong [10]. Dự đoán OP cho mô hình nhiều phương tiện kết nối (IoV) dựa trên ML được nghiên cứu trong [11], các tác giả đề xuất giải thuật tính toán OP thời gian thực với độ chính xác 51.8% so với các giải thuật trước đó. Đánh giá hiệu năng cho mô hình thông tin gói ngắn trong mạng SWITP vạn vật kết nối (IoT) đã được đề

xuất trong [12], tỉ lệ lỗi khối trung bình (BLER) với độ chính xác cao thực hiện trong thời gian ngắn so với phương pháp phân tích thông thường. Tối ưu hóa sơ đồ chòm sao dựa trên DL trong mạng TWRN được nghiên cứu trong [13], kết quả mô phỏng thu được tỉ lệ sum-rate cao hơn so với phương pháp lựa chọn nút chuyển tiếp thông thường. Ứng dụng DL cho bảo mật lớp vật lý trong mạng 6G đã được khảo sát trong [14]. Tác giả trong [15], đã thiết kế chùm tia dựa trên DL hỗ trợ hệ thống bề mặt thông minh có thể cấu hình lại (RIS: Reconfigurable intelligent surface) để đạt được hiệu năng tốt hơn trong cả hai trường hợp thông tin trạng thái kênh truyền (CSI) hoàn hảo và không hoàn hảo. Các tác giả [16] đã đề xuất phương pháp lựa chọn nút chuyển tiếp dựa trên DL để gia tăng hiệu năng bảo mật lớp vật lý.

Mạng chuyển tiếp dựa trên ML/DL để tối ưu hóa hiệu năng bảo mật, cải thiện tỉ lệ lỗi bit (BER) với ấn định công suất tại R đã được đề xuất trong [17–18]. Lựa chọn R tối ưu dựa trên DL [19] để cải thiện hiệu năng OP và dung lượng kênh truyền so với phương pháp truyền thống. Lựa chọn anten dựa trên DL để tối ưu hóa hiệu năng hệ thống đã được đề xuất trong [20]. Đánh giá hiệu năng bảo mật trong mạng NOMA SWIPT [21] với nút R sử dụng kỹ thuật mã hóa và chuyển tiếp (DF), có thu thập năng lượng dựa trên kỹ thuật phân chia năng lượng (PS: Power Switching) cho giải mã thông tin. Tác giả đã phát triển thuật toán để lựa chọn hệ số ấn định công suất tối ưu đạt được hiệu năng bảo mật tốt hơn so với phương pháp thông thường.

Khác với các nghiên cứu ở trên, bài báo này đề xuất một phương pháp độ phức tạp thấp để dự đoán OP cho mô hình TWRN có EH dùng kỹ thuật DL. Hàm học sâu (AI) dựa trên DL giảm thời gian tính toán và hiệu quả so với phương pháp thông thường. Để giảm thời gian mô phỏng OP, chúng tôi đưa ra một mô hình học sâu để dự đoán chính xác OP. Đặc biệt, chúng tôi xây dựng một mạng nơ-ron học sâu (DNN) để nắm bắt mối quan hệ giữa các tham số hệ thống và OP tương ứng, có thể dự đoán hiệu quả tham số OP cho các tình huống thực tế khác nhau cần quan tâm.

## II. MÔ HÌNH HỆ THỐNG


Xem xét mô hình hệ thống như trình bày ở **Hình 1** với  $S_1$  và  $S_2$  là hai nút nguồn trao đổi thông tin với nhau qua sự trợ giúp của nút R có thu thập năng lượng, sử dụng kênh truyền fading Rayleigh. Trong **Hình 2**, nút R sử dụng kỹ thuật AF và PS.

Tác giả liên hệ: Nguyễn Hữu Phong,

Email: phongsolo@gmail.com


Đến tòa soạn: 5/2023, chỉnh sửa: 6/2023, chấp nhận đăng:

7/2023.



Hình 1: Mô hình nghiên cứu

Gọi  $h_1, h_2$  là hệ số kênh truyền từ  $S_1 \rightarrow R, S_2 \rightarrow R$  và  $\hat{h}_1, \hat{h}_2$  lần lượt là hệ số kênh truyền  $R \rightarrow S_1, R \rightarrow S_2$ . Hệ thống sử dụng kỹ thuật ghép kênh phân chia theo thời gian (TDD: Time Division Duplexing), giả sử rằng các kênh đối xứng, nghĩa là  $h_1 = \hat{h}_1, h_2 = \hat{h}_2$ . Ở kênh truyền fading Rayleigh, độ lợi kênh truyền tương ứng  $|h_i|^2$  có phân bố mũ với tham số đặc trưng  $\gamma_i = |h_i|^2 / d_i^\psi$ , trong đó  $d_i$  là khoảng cách giữa hai nút,  $\psi$  là hệ số mũ suy hao đường truyền phụ thuộc vào môi trường truyền dẫn thường có giá trị từ 2–6 [22].



Hình 2: Kỹ thuật PS tại nút R

Trong **Hình 2**, R sẽ thu thập năng lượng trong khoảng thời gian  $\alpha T$ , năng lượng này sẽ được sử dụng để R chuyển tiếp thông tin trong pha tiếp theo  $(1-\alpha)T$ . Quá trình để truyền tín hiệu từ  $S \rightarrow R$  và ngược lại bao gồm hai pha. Ở trong Pha 1 từ  $S_1 \rightarrow R$ , tín hiệu nhận được tại nút R được cho bởi

$$y_r = \sqrt{P_1}h_1x_1 + \sqrt{P_2}h_2x_2 + n_r, \quad (1)$$

trong đó,  $P_1$  và  $P_2$  là công suất phát từ nút  $S_1$  và  $S_2$ ,  $x_1$  là symbol truyền từ nút  $S_1$ ,  $x_2$  là symbol truyền từ nút  $S_2$ ,  $n_r$  là nhiễu Gaussian tại nút R với phương sai  $\sigma_r^2$ .

Tại nút R, tín hiệu thu được phân chia thành hai phần bởi bộ phân chia năng lượng theo PS, một phần cho thu thập năng lượng  $[\sqrt{\lambda}(\sqrt{P_1}h_1x_1 + \sqrt{P_2}h_2x_2)]$  và một phần cho xử lý thông tin  $[\sqrt{1-\lambda}(\sqrt{P_1}h_1x_1 + \sqrt{P_2}h_2x_2)]$ , với  $0 < \lambda < 1$  là hệ số phân chia năng lượng [23].

Năng lượng thu thập trong Pha 1 là

$$E_r = \eta\lambda\alpha(P_1|h_1|^2 + P_2|h_2|^2), \quad (2)$$

Công suất truyền tại R

$$P_r = \frac{E_r}{1-\alpha} = \frac{\eta\lambda\alpha(P_1|h_1|^2 + P_2|h_2|^2)}{1-\alpha}, \quad (3)$$

Tại nút R, tín hiệu thu được  $y_r$  sẽ được chuyển đổi từ băng thông cao sang băng tần cơ bản và khuếch đại bởi hệ số  $\beta$  của kỹ thuật AF tại R

$$x_r = \beta\hat{y}_r, \quad (4)$$

trong đó

$$\hat{y}_r = \sqrt{(1-\lambda)P_1}h_1x_1 + \sqrt{(1-\lambda)P_2}h_2x_2 + \sqrt{(1-\lambda)}n_r, \quad (5)$$

với  $n_b$  là nhiễu Gaussian do xử lý RF đến băng tần cơ sở.

Hệ số khuếch đại của AF là

$$\begin{aligned} \beta &= \frac{\sqrt{P_r}}{\sqrt{(1-\lambda)P_1|h_1|^2 + (1-\lambda)P_2|h_2|^2 + (1-\lambda)\sigma_r^2}} \\ &\approx \frac{\sqrt{P_r}}{\sqrt{(1-\lambda)P_1|h_1|^2 + (1-\lambda)P_2|h_2|^2}} \\ &= \frac{\eta\lambda\alpha}{\sqrt{(1-\alpha)(1-\lambda)}} \end{aligned}, \quad (6)$$

Tín hiệu nhận tại nút  $S_1$  và  $S_2$  lần lượt là  $y_1$  và  $y_2$ . Sau một số bước biến đổi ta thu được

$$\begin{aligned} y_1 &= h_1x_r + n_1 = h_1\beta\hat{y}_r + n_1 \\ &= h_1\beta\sqrt{1-\lambda}(\sqrt{P_1}h_1x_1 + \sqrt{P_2}h_2x_2 + n_r) + n_1, \end{aligned} \quad (7)$$

và

$$\begin{aligned} y_2 &= h_2x_r + n_2 = h_2\beta\hat{y}_r + n_2 \\ &= h_2\beta\sqrt{1-\lambda}(\sqrt{P_1}h_1x_1 + \sqrt{P_2}h_2x_2 + n_r) + n_2, \end{aligned} \quad (8)$$

trong đó,  $n_1$  và  $n_2$  lần lượt là nhiễu Gaussian tại  $S_1$  và  $S_2$ .

Sau khi các nút  $S_1$  và  $S_2$  loại bỏ thành phần tự can nhiễu (SI: self-interference) là tín hiệu  $x_1, x_2$  sử dụng các kỹ thuật mã mạng [24]. Tỷ số tín hiệu trên nhiễu nhận được tại nút  $S_1$  và  $S_2$  là

$$\gamma_1 = \frac{P_2(1-\lambda)\beta^2|h_1|^2|h_2|^2}{\beta^2|h_1|^2(1-\lambda)\sigma_r^2 + \sigma_1^2}, \quad (9)$$

$$\gamma_2 = \frac{P_1(1-\lambda)\beta^2|h_1|^2|h_2|^2}{\beta^2|h_2|^2(1-\lambda)\sigma_r^2 + \sigma_2^2}, \quad (10)$$

với  $h_1$  và  $h_2$  là hệ số kênh truyền có phân bố fading Rayleigh. Do đó, đặt  $X = |h_1|^2$  và  $Y = |h_2|^2$  sẽ có phân bố mũ. Hàm pdf của phân bố mũ được cho bởi

$$f_{|h_i|^2}(x) = \lambda_i e^{-\lambda_i x}, \quad (11)$$

các độ lợi kênh truyền được ký hiệu là  $|h_i|^2, i \in \{1, 2\}$  sẽ có phân bố mũ với giá trị trung bình  $\mu_i = 1/\lambda_i = \Xi\{|h_i|^2\}$ , trong đó  $\Xi\{\cdot\}$  là toán tử kỳ vọng.

### Tỉ số SNR của hệ thống:

Từ (9) và (10), sau một vài phép biến đổi và đặt biến

$$X = |h_1|^2; Y = |h_2|^2; b = \beta^2(1-\lambda)\sigma_r^2; c = \sigma_1^2; d = P_1(1-\lambda)\beta^2$$

Sơ đồ TWHF dựa trên AF tại R, SNR tổng thể tại  $S_1$  và  $S_2$  là

$$\gamma_1 = \frac{aXY}{bX+c}, \quad (12)$$

$$\gamma_2 = \frac{dXY}{bY+c}. \quad (13)$$

trong đó, X và Y là các biến ngẫu nhiên có phân bố mũ.

## III. PHÂN TÍCH HIỆU NĂNG

### A. Tính toán OP

Theo tài liệu [25], hiệu năng OP của sơ đồ TWRN định nghĩa bởi

$$P_{out}^{TWRN} = \Pr(\gamma_1 < \tau, \text{ or } \gamma_2 < \tau) = \underbrace{\Pr(\gamma_1 < \tau)}_{Pr_1} + \underbrace{\Pr(\gamma_2 < \tau)}_{Pr_2} - \underbrace{\Pr(\{\gamma_1 < \tau\} \cap \{\gamma_2 < \tau\})}_{Pr_3} \quad (14)$$

trong đó các thành phần xác suất  $Pr_1, Pr_2, Pr_3$  được tính toán như bên dưới.

Trước tiên, theo định nghĩa lý thuyết xác suất, thành phần  $Pr_1$

$$Pr_1 = \Pr(\gamma_1 < \tau) = \Pr\left(\frac{aXY}{bX + c} < \tau\right), \quad (15)$$

Từ (15) có thể viết lại như sau

$$Pr_1 = \Pr\left(Y < \frac{\tau\{bX + c\}}{aX}\right) = \int_0^{\infty} F_Y\left(\frac{\tau\{bX + c\}}{aX}\right) f_X(x) dx \quad (16)$$

Khai triển tích phân (16) ta thu được

$$\begin{aligned} Pr_1 &= \int_0^{\infty} \left(1 - e^{-\lambda_1 \frac{\tau\{bX + c\}}{aX}}\right) \lambda_1 e^{-\lambda_1 x} dy \\ &= 1 - \int_0^{\infty} e^{-\lambda_1 \frac{\tau\{bX + c\}}{aX}} \lambda_1 e^{-\lambda_1 x} dx \\ &= 1 - \lambda_1 e^{-\frac{\lambda_1 b \tau}{a}} \int_0^{\infty} e^{-\frac{\lambda_1 c \tau}{ax} - \lambda_1 x} dx \\ &= 1 - \lambda_1 e^{-\frac{\lambda_1 b \tau}{a}} \int_0^{\infty} e^{-\frac{4\lambda_1 c \tau}{a^2 x} - \lambda_1 x} dx \end{aligned} \quad (17)$$

Áp dụng công thức (3.324.1, [26]) ta được

$$Pr_1 = 1 - \lambda_1 e^{-\frac{\lambda_1 b \tau}{a}} \sqrt{\frac{4\lambda_2 c \tau}{a\lambda_1}} K_1\left(\sqrt{\frac{4\lambda_1 \lambda_2 c \tau}{a}}\right), \quad (18)$$

với  $K_1(\cdot)$  là hàm Bessel bậc 1.

Sử dụng khai triển tương tự như  $Pr_1$ , ta có

$$\begin{aligned} Pr_2 &= \Pr(\gamma_2 < \tau) \\ &= 1 - \lambda_2 e^{-\frac{\lambda_2 b \tau}{a}} \sqrt{\frac{4\lambda_1 c \tau}{d\lambda_2}} K_1\left(\sqrt{\frac{4\lambda_1 \lambda_2 c \tau}{d}}\right), \end{aligned} \quad (19)$$

Cuối cùng, thành phần  $Pr_3$  trong công thức (14) được tính như sau

$$\begin{aligned} Pr_3 &= \Pr(\{\gamma_1 < \tau\} \cap \{\gamma_2 < \tau\}) \\ &= \Pr\left(\left\{\frac{axy}{bx + c} < \tau\right\} \cap \left\{\frac{dxy}{by + c} < \tau\right\}\right) \\ &= \Pr\left(\left\{y < \frac{\tau(bx + c)}{ax}\right\} \cap \left\{x < \frac{\tau(by + c)}{dy}\right\}\right) \\ &= \int_0^{\frac{\tau(b+c)}{a}} \int_{\frac{\tau}{x}}^{\frac{\tau}{y}} f_{x,y}(x, y) dy dx + \int_0^{\frac{\tau(b+c)}{d}} \int_{\frac{\tau}{y}}^{\frac{\tau}{x}} f_{x,y}(x, y) dx dy \\ &= P_1 + P_2 \end{aligned} \quad (20)$$

với các thành phần  $P_1$  và  $P_2$  được cho bởi

$$\begin{aligned} P_1 &= T_1 + T_2 = -\lambda_1 e^{-\frac{\lambda_1 b \tau}{a}} (T_{11} + T_{12}) \\ &= -\frac{\lambda_1}{\lambda_2 y_0 + \lambda_1} \left( e^{-\left(\frac{\lambda_1 y_0}{x_0} + \lambda_1\right) x_0} - 1 \right) \\ &= -\lambda_1 e^{-\frac{\lambda_1 b \tau}{a}} \left( \sqrt{\frac{\beta_1}{\lambda_1}} K_1(\sqrt{\beta_1 \lambda_1}) - \sum_{t=0}^{\infty} \frac{(-1)^t \phi_1^t}{t!} (x_0)^{t-1} E_t(\lambda_1 x_0) \right) \\ &= -\frac{\lambda_1}{\lambda_2 y_0 + \lambda_1} \left( e^{-\left(\frac{\lambda_1 y_0}{x_0} + \lambda_1\right) x_0} - 1 \right) \end{aligned} \quad (21)$$

và

$$\begin{aligned} P_2 &= -\lambda_2 e^{-\frac{\lambda_2 b \tau}{d}} \left( \sqrt{\frac{\beta_2}{\lambda_2}} K_1(\sqrt{\beta_2 \lambda_2}) - \sum_{t=0}^{\infty} \frac{(-1)^t \phi_2^t}{t!} (y_0)^{t-1} E_t(\lambda_2 y_0) \right) \\ &= -\frac{\lambda_2}{\lambda_1 x_0 + \lambda_2} \left( e^{-\left(\frac{\lambda_2 x_0}{y_0} + \lambda_2\right) y_0} - 1 \right) \end{aligned} \quad (22)$$


thế (21) và (22) vào (20) ta thu được công thức dạng tường minh của  $Pr_3$ . Chứng minh chi tiết được thực hiện trong Phần Phụ lục của bài báo [27]. Như vậy, thay các xác suất thành phần  $Pr_1, Pr_2$  và  $Pr_3$  từ công thức (18), (19), (20) vào (14) ta được dạng đóng của OP tổng thể hệ thống bằng phương pháp phân tích.

Công thức (23) có thể tính toán bằng phương pháp phân tích số và mô phỏng. Tuy vậy, biểu thức chứa nhiều tham số đầu vào mất thời gian tính toán và mô phỏng làm tăng độ phức tạp hệ thống. Chúng tôi đề xuất phương pháp có độ phức tạp thấp để ước lượng nhanh tham số OP bằng phương pháp DL chỉ với một ngõ vào và một ngõ ra, sử dụng hàm AI để dự đoán chính xác kết quả OP.

### B. Mô hình huấn luyện

Chúng tôi thiết kế mô hình mạng DNN để dự đoán hiệu năng OP của hệ thống. Mô hình gồm một lớp ngõ vào, (L-1) lớp ẩn và một lớp ngõ ra để dự đoán OP như trong **Hình 3**.

$$\begin{aligned} P_{out}^{TWRN} &= 1 - \lambda_1 e^{-\frac{\lambda_1 b \tau}{a}} \sqrt{\frac{4\lambda_2 c \tau}{a\lambda_1}} K_1\left(\sqrt{\frac{4\lambda_1 \lambda_2 c \tau}{a}}\right) \\ &+ 1 - \lambda_2 e^{-\frac{\lambda_2 b \tau}{d}} \sqrt{\frac{4\lambda_1 c \tau}{d\lambda_2}} K_1\left(\sqrt{\frac{4\lambda_1 \lambda_2 c \tau}{d}}\right) \\ &- \lambda_1 e^{-\frac{\lambda_1 b \tau}{a}} \left( \sqrt{\frac{\beta_1}{\lambda_1}} K_1(\sqrt{\beta_1 \lambda_1}) - \sum_{t=0}^{\infty} \frac{(-1)^t \phi_1^t}{t!} (x_0)^{t-1} E_t(\lambda_1 x_0) \right) \\ &- \frac{\lambda_1}{\lambda_2 y_0 + \lambda_1} \left( e^{-\left(\frac{\lambda_1 y_0}{x_0} + \lambda_1\right) x_0} - 1 \right) \\ &- \lambda_2 e^{-\frac{\lambda_2 b \tau}{d}} \left( \sqrt{\frac{\beta_2}{\lambda_2}} K_1(\sqrt{\beta_2 \lambda_2}) - \sum_{t=0}^{\infty} \frac{(-1)^t \phi_2^t}{t!} (y_0)^{t-1} E_t(\lambda_2 y_0) \right) \\ &- \frac{\lambda_2}{\lambda_1 x_0 + \lambda_2} \left( e^{-\left(\frac{\lambda_2 x_0}{y_0} + \lambda_2\right) y_0} - 1 \right) \end{aligned} \quad (23)$$



Hình 3: Mô hình mạng DNN


Lớp vào chứa một nơ-ron tương ứng với một nút chỉ tham số SNR. Bảng 1 tính toán SNR qua công thức (12) và (13). Ở đầu ra của mô hình chứa một nơ-ron tương ứng với ước lượng OP. SNR là tập hợp các vectơ đầu vào,  $w^{(1)}, \dots, w^{(L-1)}, w^{(L)}$  là tập hợp các trọng số của mô hình.

Mỗi lớp ẩn  $l$  với,  $l=1, \dots, L-1$  có chứa nơ-ron  $Q^{(l)}$ .

Trong đó, sử dụng mạng tin cậy Bayesian (BNN) để huấn luyện dữ liệu [28]. BNN được định nghĩa là một mạng thần kinh nhân tạo ngẫu nhiên được đào tạo bằng cách sử dụng thuật toán Bayesian. Để thiết kế mạng BNN, bước đầu tiên chọn mô hình mạng nơ-ron, ví dụ một mô hình gồm nhiều nút mạng. Tiếp theo, phải chọn một mô hình thống kê, ví dụ phân phối xác suất trên tham số mô hình có thể có  $p(\theta)$  và xác suất dự đoán của mô hình  $p(y|x, \theta)$ . Tham số hóa mô hình có thể được coi là giả thuyết  $H$  và tập huấn luyện là dữ liệu  $D$ . Khi sử dụng BNN để dự đoán, phân phối xác suất  $p(y|x, D)$  được gọi là cận biên và định lượng độ không chắc chắn của mô hình đối với dự đoán của nó, được quan tâm đặc biệt. Cho trước  $p(\theta|D)$ , xác suất  $p(y|x, D)$  có thể tính bởi

$$p(y|x, D) = \int_{\theta} p(y|x, \theta) p(\theta|D) d\theta, \quad (24)$$

Công thức (24) sử dụng để dự đoán OP theo mô hình DNN trong Hình 3.



Hình 4: Tạo hàm AI trong Matlab dựa trên thuật toán Bayesian

C. Huấn luyện dữ liệu

Các dữ liệu đầu vào SNR dạng vector là các tham số được tạo ra trong MatLab theo công thức (12) và (13), kèm theo OP tương ứng theo công thức (23), các giá trị đầu vào tính toán OP được cho trong Bảng 1. Quá trình huấn luyện dữ liệu sử dụng giải thuật Bayesian, như mô tả trong Hình 4. Kết quả huấn luyện được hàm AI, hàm này dùng để dự đoán OP của hệ thống. Trong đó, số lớp ẩn tối ưu được chọn ứng với tham số lỗi trung bình bình phương (RMSE) nhỏ nhất. Trong mô hình của chúng tôi, tập dữ liệu được

chia thành 70% cho tập huấn luyện, 30% còn lại chia đều cho tập đánh giá và tập kiểm thử.

Bảng 1: Các tham số đầu vào mô phỏng

STT	Tham số	Giá trị
1	Tốc độ truyền dẫn mục tiêu $R_b$	0.5 bit/s/Hz
2	Time Block T	1
3	Hệ số phân chia thời gian $\alpha$	0.5
4	Hệ số phân chia năng lượng $\lambda$	0.5
5	Vị trí của $S_1$	[0.0; 0.0]
6	Vị trí của $S_2$	[1.0; 0.0]
7	Vị trí của R	[0.5; 0]
8	Hệ số mũ suy hao $\psi$	3
9	Phương sai nhiễu $\sigma^2$	1
10	Hiệu suất chuyển đổi năng lượng $\eta$	0.5
11	Số phép thử Monte-Carlo (N)	$10^5$

IV. KẾT QUẢ MÔ PHỎNG

Trong phần này, chúng tôi trình bày kết quả mô phỏng để đánh giá OP của hệ thống được đề xuất, đồng thời so sánh kết quả bằng cách sử dụng phương pháp mô phỏng Monte Carlo, phân tích lý thuyết OP và dự đoán bằng hàm AI. Giả định rằng vị trí của các phân tử trong toàn bộ mạng được đặt tại các tọa độ  $(x, y)$  với tọa độ tương ứng:  $S_1(0, 0)$ ,  $S_2(1, 0)$  và  $R(0.5, 0)$ . Các tham số mô phỏng khác được trình bày trong Bảng 1. Công suất phát của nút nguồn  $S_1$  và  $S_2$  chọn bằng:  $P=P_1=P_2$ . Phương sai nhiễu tại các nút chuẩn hóa:  $\sigma^2 = \sigma_r^2 = \sigma_1^2 = \sigma_2^2 = 1$ .

Tiếp theo, chúng tôi trình bày các kết quả mô phỏng để so sánh kết quả OP lý thuyết và phương pháp tính toán OP của hàm AI được đề xuất. Mô hình mạng DNN trong Hình 3 với các mẫu đầu vào được huấn luyện 3 lần, hàm AI là mối quan hệ giữa đầu vào SNR và đầu ra OP tương ứng. Quá trình huấn luyện tạo ra hàm AI, với kết quả RMSE được chọn nhỏ nhất. Tham số RMSE được tính toán như Bảng 2 bên dưới theo số lớp ẩn.

A. Đánh giá RMSE

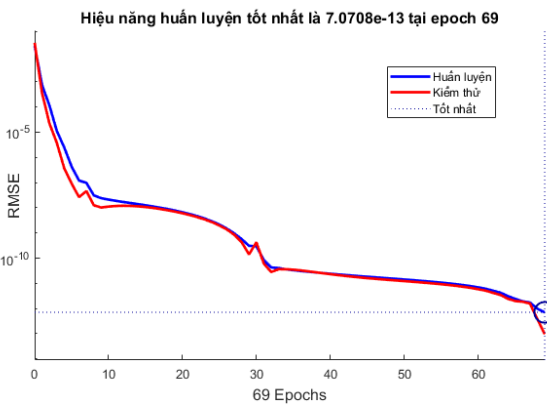
Để đánh giá sai số của mô hình dựa trên DNN được đề xuất trong sơ đồ để dự đoán OP mục tiêu. RMSE được sử dụng để đo lường sự khác biệt giữa giá trị OP thực tế  $OP_m$  theo công thức (23) và giá trị OP được dự đoán  $OP_m$  công thức (24) trong toàn bộ tập thử nghiệm. Phương pháp RMSE dựa trên mô hình có thể tính toán bởi:

$$RMSE = \sqrt{\frac{1}{M} \sum_{m=1}^M (OP_m - \hat{OP}_m)^2} \quad (25)$$

trong đó  $\bar{M}$  biểu thị tổng số mẫu trong bộ thử nghiệm.

Bảng 2: So sánh RMSE

Số lớp ẩn	Epoch	RMSE
1	54	$1.2894 \times 10^{-9}$
2	93	$4.0463 \times 10^{-11}$
3	91	$3.7341 \times 10^{-12}$
4	62	$1.0097 \times 10^{-10}$
5	62	$1.5866 \times 10^{-12}$
6	69	$7.0708 \times 10^{-13}$
7	62	$8.4542 \times 10^{-13}$
8	100	$1.0731 \times 10^{-12}$




Hình 5: RMSE với 6 lớp ẩn

**Bảng 2** trình bày RMSE tương ứng với hàm AI có từ 1–8 lớp ẩn. Hàm AI tạo bởi mô hình DNN được sử dụng để dự đoán tham số OP của hệ thống. Có thể quan sát thấy rằng khi số lượng lớp ẩn tăng lên, giá trị của RMSE thấp hơn, OP được ước tính gần chính xác kết quả lý thuyết. Điều này là do mô hình DNN có nhiều lớp ẩn có khả năng tổng quát hóa tập dữ liệu, dẫn đến cải thiện hiệu năng mạng, trong khi mạng nơ-ron một lớp không học được các mẫu phức tạp trong tập dữ liệu chiều sâu dẫn đến RMSE cao. Tuy vậy, khi số lớp ẩn gia tăng, thời gian tính toán và độ phức tạp mạng DNN cũng tăng theo. Từ kết quả mô phỏng, RMSE nhỏ nhất tối ưu với 6 lớp ẩn, được chọn để ước lượng tham số OP của hệ thống theo phương pháp DL.

**Hình 5** vẽ minh họa RMSE của mô hình DL theo số lớp ẩn bằng 6 lớp, kết quả tốt nhất khi số lớp ẩn bằng 6 đạt được với 69 epoch. Giá trị RMSE đạt được tương ứng là  $7.0708 \times 10^{-13}$ .

**B. Đánh giá OP**

**Hình 6** mô phỏng OP theo SNR ứng với hai trường hợp. Trường hợp 1: tốc độ bit  $R_b=0.2$  bit/s/Hz, số phép thử Monte-Carlo  $N=10^5$  và Trường hợp 2: tốc độ bit  $R_b=0.5$  bit/s/Hz và số phép thử Monte-Carlo  $N=10^6$ . Các tham số mô phỏng còn lại được trình bày trong **Bảng 1**. ‘Theory.’ là đường nét liền OP lý thuyết theo công thức toán dạng tường minh (23). ‘Sim.’ là đường mô phỏng OP theo lý thuyết sắc xuất với số phép thử là  $N=10^5$  và  $N=10^6$ . ‘AI 6 lớp’ là kết quả OP vẽ bởi hàm dự đoán AI sử dụng mạng DNN với 6 lớp ẩn. Có thể nhận thấy kết quả trùng khớp



Hình 6: OP thông qua SNR

giữa tính toán lý thuyết công thức (23) và phương pháp Monte-Carlo, xác minh cho tính chính xác của biểu thức OP đề xuất. Khi SNR gia tăng đảm bảo ngưỡng SNR đầu vào tại mức tối thiểu duy trì hoạt động hệ thống. Ngoài ra, xác suất OP gia tăng khi tăng tốc độ bit  $R_b$  từ 0.2 bit/s/Hz đến 0.5 bit/s/Hz. Hàm AI với 6 lớp ẩn đề xuất tính toán chính xác giá trị OP cho cả hai trường hợp minh chứng cho tính hiệu quả của phương pháp ước lượng OP bằng DL.

**C. Đánh giá thời gian thực hiện**

Tiếp theo, chúng tôi đánh giá thời gian thực thi của hàm AI được đề xuất và thời gian tính toán OP bằng mô phỏng và tính toán OP theo lý thuyết, như được hiển thị trong **Bảng 3**. Mô phỏng được thực hiện với phần mềm Matlab R2018a, trên máy tính chạy hệ điều hành Win10 64bit, CPU Core i5-8250, 8GB RAM.

Thời gian thực hiện trong **Bảng 3** được định nghĩa là thời gian dành cho hệ thống được coi là thực thi thuật toán. Kết quả cho thấy rằng hàm AI được đề xuất tốn thời gian thực thi rất ngắn, ngay cả khi xử lý các tình huống quy mô lớn. Ví dụ so sánh kết quả chạy mô phỏng OP theo Monte-carlo kết quả phân tích lý thuyết và mô hình DL. Thời gian chạy mô phỏng: Mô phỏng Monte-carlo với số phép thử  $10^5$  là 4.502395s. Thời gian chạy kết quả lý thuyết là 1.488841s. Chạy bằng hàm AI chỉ mất thời gian 0.000521s. Như vậy, với phương pháp dự đoán OP dùng DL, thời gian rút ngắn đáng kể so với phương pháp tính toán thông thường. Khi số phép thử tăng lên, thời gian tính toán OP theo mô phỏng cũng tăng theo, trong khi thời gian thực thi dự đoán OP bằng hàm AI không ảnh hưởng đáng kể.

Bảng 3: So sánh thời gian thực hiện

Số mẫu Monte-carlo	Tham số	Thời gian thực hiện (Monte-Calro)	Thời gian thực hiện (Lý thuyết)	Thời gian thực hiện (AI)
$10^5$	OP	4.502395s	1.488841s	0.000521s
$10^6$	OP	66.476738s	0.654479s	0.000278s

**V. KẾT LUẬN**

Bài báo này đã đề xuất dự đoán OP độ phức tạp thấp dựa trên kỹ thuật DL và mô hình DNN. Kết quả thực hiện với thời gian tính toán OP giảm đáng kể sử dụng phương pháp DL. Kết quả mô phỏng OP trùng khớp giữa mô hình toán

và hàm dự đoán dùng phương pháp DL minh chứng cho tính chính xác của hàm AI đề xuất. Kết quả dự đoán OP tối ưu được huấn luyện với 6 lớp ẩn. 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. Sử dụng mô hình DNN để dự đoán OP giúp tiết kiệm thời gian hơn nhiều so với phương pháp mô phỏng và phân tích.

REFERENCES

[1] Z. Zhang, Z. Ma, Z. Ding, M. Xiao, and G. K. Karagiannidis, "Full-duplex two-way and one-way relaying: average rate, outage probability, and tradeoffs," *IEEE Transactions on Wireless Communications*, vol. 15, no. 6, pp. 3920-3933, 2016.

[2] J. Liu *et al.*, "The Intelligent Bi-directional Relaying Communication for Edge Intelligence based Industrial IoT Networks: Intelligent Bi-directional Relaying Communication," vol. 9, no. 32, pp. e4-e4, 2022.

[3] L. J. I. T. o. V. T. Song, "Relay selection for two-way relaying with amplify-and-forward protocols," vol. 60, no. 4, pp. 1954-1959, 2011.

[4] G. J. K. T. o. I. Li and I. Systems, "A Spectral Efficient NOMA-based Two-Way Relaying Scheme for Wireless Networks with Two Relays," vol. 15, no. 1, pp. 365-382, 2021.

[5] X. Guo, B. Li, D. Zhai, and R. J. I. I. o. T. J. Zhang, "Performance analysis and optimization of a UAV-enabled two-way relaying network under FSMH, NC, and PNC schemes," vol. 8, no. 24, pp. 17802-17816, 2021.

[6] L. Ma, E. Li, X. Wang, M. Gu, and Q. J. I. N. Yang, "Outage probability analysis of overlay cognitive two-way relaying scheme with opportunistic relay selection," vol. 10, no. 5, pp. 230-243, 2021.

[7] G. Prasad and D. Mishra, "Deep learning based integrated information and energy relaying in RF powered communication," in *2021 IEEE International Conference on Communications Workshops (ICC Workshops)*, 2021, pp. 1-6: IEEE.

[8] J. Zhang and K. B. J. P. o. t. I. Letaief, "Mobile edge intelligence and computing for the internet of vehicles," vol. 108, no. 2, pp. 246-261, 2019.

[9] K. Ko, J. K. Lee, M. Kang, J. Jeon, and H. J. I. T. o. E. D. Shin, "Prediction of process variation effect for ultrascaled GAA vertical FET devices using a machine learning approach," vol. 66, no. 10, pp. 4474-4477, 2019.

[10] T.-H. Vu, T.-V. Nguyen, and S. J. I. I. o. T. J. Kim, "Cooperative NOMA-enabled SWIPT IoT networks with imperfect SIC: Performance analysis and deep learning evaluation," vol. 9, no. 3, pp. 2253-2266, 2021.

[11] L. Xu, X. Yu, and T. A. J. I. T. o. V. T. Gulliver, "Intelligent outage probability prediction for mobile IoT networks based on an IGWO-elman neural network," vol. 70, no. 2, pp. 1365-1375, 2021.

[12] C. D. Ho, T.-V. Nguyen, T. Huynh-The, T.-T. Nguyen, D. B. da Costa, and B. J. I. T. o. V. T. An, "Short-packet communications in wireless-powered cognitive IoT networks: Performance analysis and deep learning evaluation," vol. 70, no. 3, pp. 2894-2899, 2021.

[13] T. Matsumine, T. Koike-Akino, and Y. Wang, "Deep learning-based constellation optimization for physical network coding in two-way relay networks," in *ICC 2019-2019 IEEE International Conference on Communications (ICC)*, 2019, pp. 1-6: IEEE.

[14] B. Ozpoyraz, A. T. Dogukan, Y. Gevez, U. Altun, and E. J. a. p. a. Basar, "Deep learning-aided 6G wireless networks: A comprehensive survey of revolutionary PHY architectures," 2022.

[15] W. Xu, L. Gan, C. J. I. T. o. C. C. Huang, and Networking, "A robust deep learning-based beamforming design for RIS-assisted multiuser MISO communications with practical constraints," 2021.

[16] M. A. Salem *et al.*, "Machine Learning-Based Node Selection for Cooperative Non-Orthogonal Multi-Access System Under Physical Layer Security," 2019.

[17] J. Xing, T. Lv, and X. Zhang, "Cooperative relay based on machine learning for enhancing physical layer security," in *2019 IEEE 30th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, 2019, pp. 1-6: IEEE.

[18] T. Bao, J. Zhu, H.-C. Yang, and M. O. J. I. W. C. L. Hasna, "Secrecy outage performance of ground-to-air communications with multiple aerial eavesdroppers and its deep learning evaluation," vol. 9, no. 9, pp. 1351-1355, 2020.

[19] W. Jiang and H. D. J. I. T. o. V. T. Schotten, "A simple cooperative diversity method based on deep-learning-aided relay selection," vol. 70, no. 5, pp. 4485-4500, 2021.

[20] R. Yao, Y. Zhang, S. Wang, N. Qi, T. A. Tsiftsis, and N. I. J. a. p. a. Miridakis, "Deep Learning Assisted Antenna Selection in Untrusted Relay Networks," 2019.

[21] F. Jameel, W. U. Khan, Z. Chang, T. Ristaniemi, and J. Liu, "Secrecy analysis and learning-based optimization of cooperative NOMA SWIPT systems," in *2019 IEEE International Conference on Communications Workshops (ICC Workshops)*, 2019, pp. 1-6: IEEE.

[22] A. Goldsmith, *Wireless communications*. Cambridge university press, 2005.

[23] A. A. Nasir, X. Zhou, S. Durrani, and R. A. Kennedy, "Relaying protocols for wireless energy harvesting and information processing," *IEEE Transactions on Wireless Communications*, vol. 12, no. 7, pp. 3622-3636, 2013.

[24] Z. Chen, Y. Dong, P. Fan, and K. B. Letaief, "Optimal Throughput for Two-Way Relaying: Energy Harvesting and Energy Co-Operation," *IEEE Journal on Selected Areas in Communications*, vol. 34, no. 5, pp. 1448-1462, 2016.

[25] Y. W. Liu, Lifeng Elkashlan, Maged Duong, Trung Q Nallanathan, Arumugam "Two-way relay networks with wireless power transfer: design and performance analysis," *IET Communications*, vol. 10, no. 14, pp. 1810-1819, 2016.

[26] I. S. Gradštejn, I. M. Ryžik, A. Jeffrey, and D. Zwillinger, *Table of integrals, series, and products*. Elsevier/Academic Press, 2007.

[27] P. Nguyen-Huu, K. Ho-Van, V. N. Q. J. R. J. o. E. Bao, and Communications, "Evaluating the effect of self-interference on the performance of full-duplex two-way relaying communication with energy harvesting," vol. 9, no. 3-4, 2020.

[28] L. V. Jospin, H. Laga, F. Boussaid, W. Buntine, and M. J. I. C. I. M. Bennamoun, "Hands-on Bayesian neural networks—A tutorial for deep learning users," vol. 17, no. 2, pp. 29-48, 2022.

## ESTIMATE THE OUTAGE PROBABILITY OF TWO-WAY RELAYING MODEL VIA RAYLEIGH FADING CHANNEL BY DEEP LEARNING METHOD

systems, cooperative and cognitive communications, physical layer security, and energy harvesting.

**Abstract:** In this paper, we propose an effective method to evaluate the performance through the outage probability (OP) of the two-way relay scheme (TWRN) based on the DL (Deep-learning) method. The considered model consists the two source nodes exchanging information with each other via the help of a relay node (R) using the energy harvesting (EH) and amplify-and-forward (AF) technique. First, the explicit OP expression is extracted. The Monte-Carlo validation simulation is performed over the Rayleigh fading channel to verify the accuracy of the proposed OP expression. Furthermore, we use a low complexity method to predict the OP through DL model. The OP simulation results coincide with the DL method.

**Keywords:** Two-way relaying, energy harvesting, deep-learning, outage probability.



**Nguyen Huu Phong** received the B.E. degree in Telecommunications Engineering from University of Transport and communications – Campus 2 (UTC2), Vietnam in 2006; and Master of Telecom from HCMC Posts and Telecommunications Institute of Technology (PTIT),

Vietnam in 2014. From June 2016, he has been working toward the PhD. degree in Faculty of Telecommunications, Ho Chi Minh city University of Technology (HCMUT). From July 2006 to June 2012, he worked as an engineer in CDMA Mobile Phone Center (S-Fone Mobile). Since July 2012, he has been a member of Research Staff in Broadcast Research and Application Center (BRAC), Vietnam Television (VTV). His research interests include the areas of mobile communication network, energy harvesting, audio/video coding and broadcast technology.



**Vo Nguyen Quoc Bao** received the Ph.D. degree in electrical engineering from University of Ulsan, South Korea, in 2010. Dr. Bao is an associate professor of Wireless Communications at Posts and Telecommunications Institute of Technology (PTIT), Vietnam. He is currently serving as

Director of the Wireless Communication Laboratory (WCOMM). He is senior member of IEEE. He is the Technical Editor in Chief of REV Journal on Electronics and Communications. He is also serving as an Editor of Transactions on Emerging Telecommunications Technologies (Wiley ETT), and VNU Journal of Computer Science and Communication Engineering. He served as a Technical Program co-chair for ATC (2013, 2014), NAFOSTED-NICS (2014, 2015, 2016), REV-ECIT 2015, ComManTel (2014, 2015), and SigComTel 2017. His research interests include wireless communications and information theory with current emphasis on MIMO