

## BỘ CÂN BẰNG PHI TUYẾN DỰA TRÊN SVM CHO HỆ THỐNG THÔNG TIN QUANG IM/DD PAM-4 CỤ LY NGẮN TỐC ĐỘ CAO

Vương Quang Phước<sup>1\*</sup>, Nguyễn Tấn Hưng<sup>2</sup>

<sup>1</sup> Khoa Điện, Điện tử và Công nghệ vật liệu, Trường Đại học Khoa học, Đại học Huế

<sup>2</sup> Viện Khoa học và Công nghệ tiên tiến, Đại học Đà Nẵng

\*Email: vqphuoc@hueuni.edu.vn

Ngày nhận bài: 24/10/2025; ngày hoàn thành phản biện: 8/11/2025; ngày duyệt đăng: 16/12/2025

### TÓM TẮT

Bài báo đề xuất bộ cân bằng phi tuyến dựa trên kỹ thuật học máy SVM, ứng dụng cho hệ thống thông tin quang cự ly ngắn sử dụng PAM-4 ở tốc độ 100 Gb/s. Mô hình đề xuất kết hợp bộ cân bằng tuyến tính FFE với mô hình SVM sử dụng hàm kernel RBF để bù méo tín hiệu do đặc tính kênh truyền và các giới hạn phần cứng. Tín hiệu thu được được xử lý theo chuỗi thời gian thông qua cơ chế cửa sổ trượt, sau đó được chuẩn hóa và phân loại theo cấu trúc SVM đa lớp với cơ chế One-vs-Rest. Kết quả mô phỏng cho thấy bộ cân bằng được đề xuất cho hiệu năng BER tốt hơn so với FFE truyền thống. Các kết quả này khẳng định tiềm năng của SVM như một giải pháp cân bằng phi tuyến hiệu quả và thực tiễn cho hệ thống quang thế hệ mới.

**Từ khóa:** Kỹ thuật cân bằng, IM/DD, Méo phi tuyến, PAM-4, Support Vector Machine (SVM)

### 1. MỞ ĐẦU

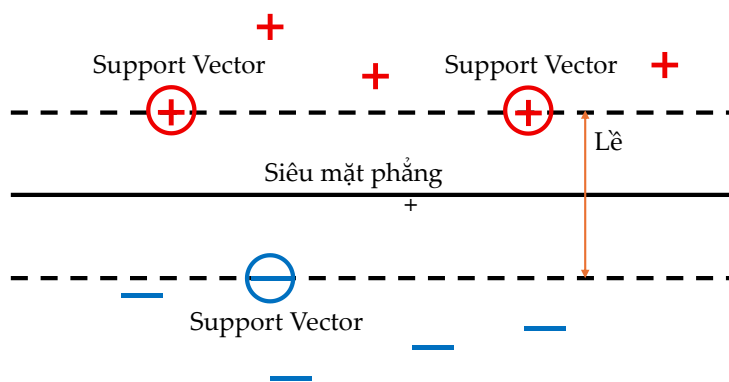
Những năm gần đây, thị trường đã có sự dịch chuyển mạnh từ các tuyến đường trục sang đầu tư vào các tuyến quang cự ly ngắn, nhằm đáp ứng sự bùng nổ lưu lượng dữ liệu phần lớn đến từ các kết nối giữa các trung tâm dữ liệu (DCI) và các đường truyền trong mạng fronthaul [1, 2]. Trong bối cảnh đó, hệ thống thông tin quang sử dụng kỹ thuật điều chế cường độ/giải điều chế trực tiếp (IM/DD) kết hợp với định dạng điều chế PAM-4 đã trở thành giải pháp hàng đầu cho hệ thống truyền dẫn tốc độ cao, với các ưu điểm: chi phí thấp, cấu trúc đơn giản và khả năng mở rộng tốt [2, 3]. Tuy nhiên, khi tốc độ vượt quá 100 Gb/s, các hệ thống này phải đối mặt với nhiều vấn đề suy hao tín hiệu do sự giới hạn về mặt phần cứng của thiết bị thu phát hay các suy giảm trên kênh truyền dẫn đến các hiện tượng nhiễu, méo tuyến tính lẫn phi tuyến [2, 4]. Trong khi đó, bộ cân bằng tuyến tính truyền thống như FFE chỉ khắc phục được méo tuyến tính, nên không

thật sự hiệu quả khi hệ thống truyền dẫn có méo/biến dạng phi tuyến phức tạp [5].

Để cải thiện chất lượng tín hiệu, nhiều nghiên cứu gần đây đã khai thác và ứng dụng kỹ thuật học máy (ML) trong thiết kế bộ cân bằng [6]. Các nghiên cứu gần đây cho thấy, những mô hình ML đã phần nào học và xử lý các đặc trưng phi tuyến từ dữ liệu nhận mà không cần biết trước về kênh truyền [7-9]. Tuy nhiên, các mô hình này thường có số lượng tham số lớn, thời gian huấn luyện dài và đòi hỏi phần cứng tính toán chuyên dụng, khiến việc tích hợp vào các bộ thu giá rẻ trở nên khó khăn. Theo đó, các thuật toán học máy cổ điển vốn có cấu trúc nhẹ và độ phức tạp thấp, phù hợp hơn cho các thiết bị phần cứng hạn chế. Trong số các thuật toán ML cổ điển, SVM là một mô hình tiêu biểu nhờ khả năng phân loại dữ liệu thông qua việc xác định mặt phẳng phân lớp và hoạt động hiệu quả với các tập dữ liệu vừa và nhỏ [6]. Cùng với sự phát triển của các thuật toán, với kernel Gaussian RBF thì mô hình SVM có thể ánh xạ dữ liệu sang không gian phi tuyến để cải thiện phân lớp tín hiệu PAM-4 trong môi trường méo nặng. Một số nghiên cứu ban đầu cho thấy sự hiệu quả của SVM trong cân bằng tín hiệu PAM-4 [10, 11]. Tuy nhiên, phần lớn các phương pháp này vẫn dựa trên nhiều mô hình sử dụng mặt phẳng đơn hoặc tốc độ truyền còn thấp, chưa thực sự phù hợp với nhu cầu hiện tại. Trên cơ sở đó, bài báo này đề xuất cấu hình kết hợp mô hình cân bằng ghép lai FFE và SVM với chiến lược đa lớp OvR cho hệ thống thông tin quang PAM-4 ở tốc độ 100 Gb/s. Quá trình tối ưu siêu tham số hướng tới tăng khả năng phân loại ký tự PAM-4 và giảm tỷ lệ lỗi bit BER. Từ đó, giúp mô hình phù hợp với các tuyến IM/DD dưới nhiều điều kiện méo tuyến tính và phi tuyến khác nhau.

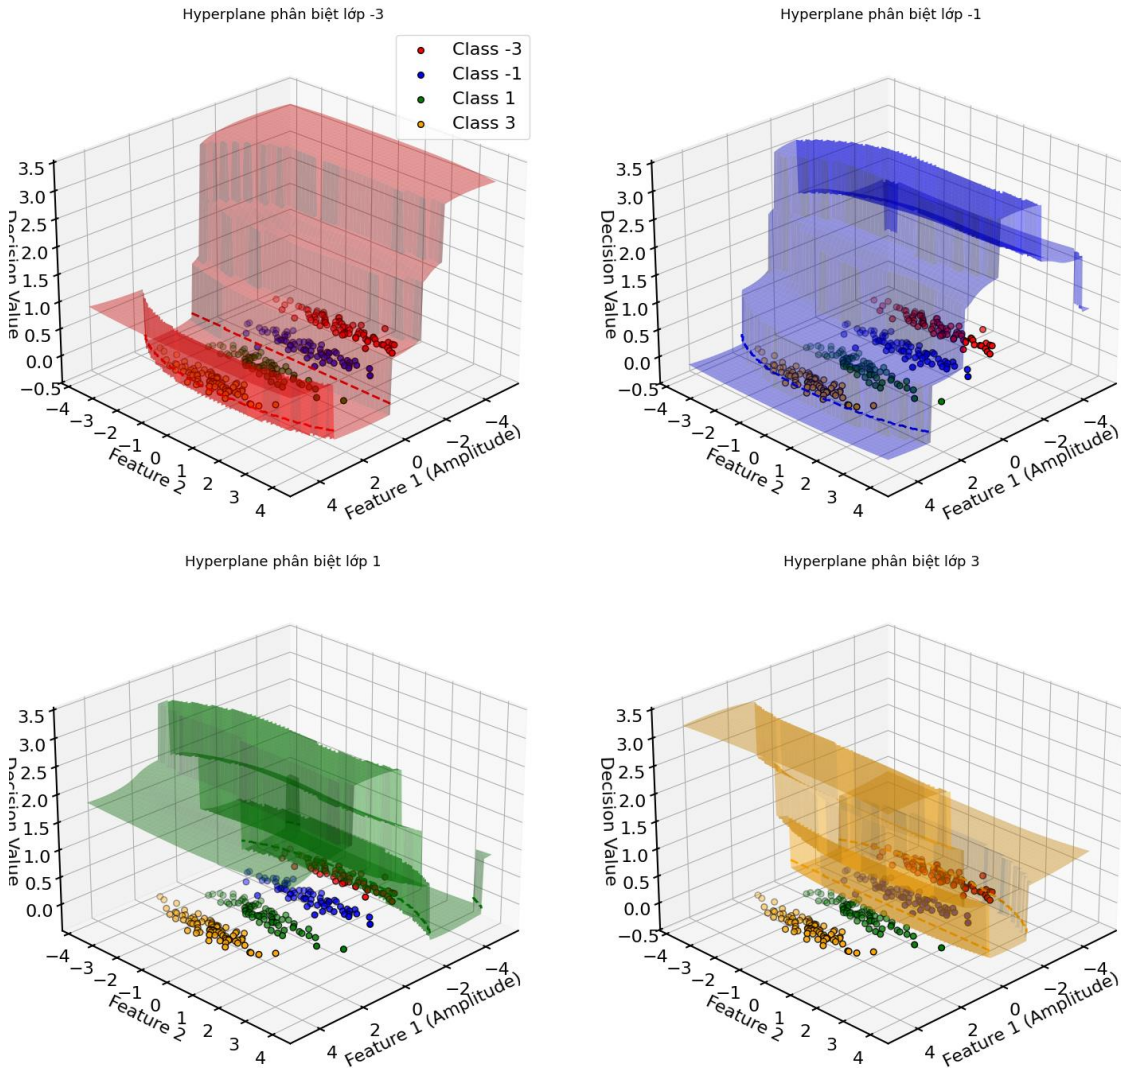
## 2. CƠ SỞ LÝ THUYẾT

SVM là thuật toán học máy giám sát (supervised learning) dùng cho phân loại và hồi quy [6]. Với bài toán hai lớp, SVM tìm siêu mặt phẳng phân tách có biên cách xa nhất, đồng thời đảm bảo tính chính xác của phân loại trên tập huấn luyện với nguyên lý tối đa hóa độ rộng của biên phân tách, qua đó cải thiện khả năng tổng quát hóa của mô hình đối với dữ liệu mới [6, 12].



Hình 1. Sử dụng thuật toán SVM để tối đa hóa chiều rộng của lề giữa hai lớp (+ / -) và được phân tách bằng một siêu mặt phẳng.

Trong trường hợp dữ liệu có thể tách tuyến tính hoàn toàn, SVM tìm một siêu mặt phẳng (Hyperplane) trong không gian đặc trưng sao cho khoảng cách từ biên đến các mẫu gần nhất của hai lớp là lớn nhất (Hình 1). Hyperplane được mô tả bởi  $w^T x + b = 0$  ( $w$  là vector trọng số và  $b$  là bias).



**Hình 2.** Minh họa các siêu mặt phẳng quyết định và giá trị hàm quyết định của bộ phân loại SVM sử dụng kernel RBF được huấn luyện theo chiến lược One-vs-Rest (OvR) trên dữ liệu điều chế PAM4.

Tuy nhiên, trong hệ thống thông tin quang tốc độ cao, dữ liệu thu không chỉ bị ảnh hưởng bởi các yếu tố tuyến tính mà còn có cả yếu tố phi tuyến. Điều này khiến việc sử dụng các mặt phẳng tuyến tính để tách lớp dữ liệu khá khó khăn. Do vậy, ngoài việc cần tối thiểu hoá hàm  $\frac{1}{2} \| w \|^2$ , SVM còn cần sử dụng kỹ thuật “soft margin” thông qua điều chỉnh biến  $\xi_i$  để một số mẫu được phép vi phạm điều kiện đặt ra. Bài toán tối ưu lúc này được biểu diễn theo [11] như trong công thức (1):

$$\min_{w,b,\xi_i} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (1)$$

với tham số  $C$  điều chỉnh sự đánh đổi giữa độ rộng của biên phân tách và tổng lỗi phân loại trên tập huấn luyện. Giá trị  $C$  lớn giúp giảm lỗi huấn luyện nhưng có nguy cơ quá khớp trong khi  $C$  nhỏ có thể giúp cải thiện tính tổng quát hóa của mô hình.

Đối với bài toán phân loại ký tự PAM-4, do tín hiệu thực tế bị ảnh hưởng bởi méo phi tuyến khá mạnh, dữ liệu thường không thể được phân tách tuyến tính trong không gian gốc [12]. Do đó, SVM sử dụng hàm kernel để ánh xạ dữ liệu sang không gian đặc trưng bậc cao. Trong bài toán phân loại đa lớp với các hiện tượng méo phức tạp này, Radial Basis Function (RBF) là một lựa chọn tối ưu nhờ khả năng mô tả linh hoạt các siêu mặt phẳng phi tuyến [12, 13], kernel RBF được định nghĩa như sau:

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right) \quad (2)$$

trong đó  $\gamma > 0$  là tham số điều chỉnh độ cục bộ của hàm quyết định. Khi  $\gamma$  nhỏ, biên quyết định trở nên mượt và mô hình có khả năng khái quát hóa tốt hơn, ngược lại, khi  $\gamma$  lớn, ranh giới phân loại trở nên biến đổi mạnh, mô hình bám sát dữ liệu huấn luyện nhưng đồng thời cũng làm tăng nguy cơ quá khớp.


Đối với hệ thống PAM-4, mô hình SVM-RBF kết hợp chiến lược One-vs-Rest (OvR) giúp xác định bốn siêu mặt phẳng (hyperplane) quyết định sau khi thực hiện ánh xạ dữ liệu sang không gian đặc trưng có chiều cao hơn, từ đó cho phép mô hình phân tách chính xác các mức tín hiệu bị méo nặng bởi nhiễu và phi tuyến hơn [10, 14]. Biểu diễn 3D của hàm quyết định cho thấy khả năng của SVM trong việc học các biên cong, từ đó nâng cao hiệu quả cân bằng cho các hệ thống tốc độ cao, quá trình này có thể được minh họa trong Hình 2.

### 3. THIẾT KẾ BỘ CÂN BẰNG SVM

#### 3.1. Sơ đồ khối hệ thống

Hệ thống thông tin quang mô tả trong Hình 3 là cấu hình IM/DD sử dụng PAM-4 ở tốc độ truyền 100 Gb/s, được thiết kế để đánh giá hiệu quả các bộ cân bằng DSP phi tuyến. Dữ liệu nhị phân (gồm  $N = 2^{19}$  bit ngẫu nhiên) đầu tiên được ánh xạ thành các ký tự PAM-4 (symbols) và tạo xung bằng bộ lọc Raised Cosine với hệ số cuộn  $\beta = 0.1$  tại phía phát nhằm tối ưu hóa phổ tín hiệu. Sau đó, tín hiệu được điều chế quang qua Mach-Zehnder Modulator (MZM) với công suất phát 0 dBm và truyền qua sợi đơn mode (SMF) ở bước sóng 1550 nm, với lượng tán sắc tổng  $\sim 100$  ps/nm. Ở phía thu, tín hiệu được tách sóng trực tiếp bằng PIN+TIA với hệ số chuyển đổi quang-điện  $R = 0.7$  A/W, với

bằng thông máy phát/thu 25 GHz. Tín hiệu sau đó được số hóa và đưa vào chuỗi xử lý DSP để cân bằng tín hiệu.

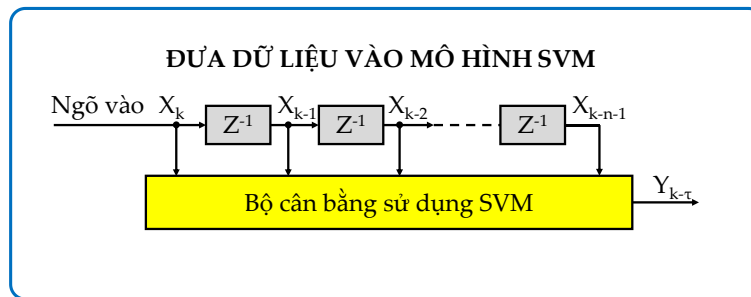


Hình 3. Mô hình hệ thống sử dụng kỹ thuật IM/DD với định dạng điều chế PAM-4.

Cấu trúc cân bằng đề xuất gồm hai tầng: đầu tiên, FFE có chiều dài bộ lọc  $L_{\text{tap}} = 15$  tap được sử dụng để loại bỏ méo tuyến tính. Sau đó, đầu ra FFE được đưa vào mô hình SVM (với kernel RBF) thông qua các bộ trễ. Sự kết hợp FFE-SVM cho phép xử lý đồng thời méo tuyến tính và phi tuyến phát sinh từ các thành phần như: bộ phát (Laser/MZM/DAC), bộ thu (PIN+TIA/ADC) hay kênh truyền SMF. Ngoài ra, nhiễu AWGN cũng được chèn vào mô phỏng để đánh giá độ ổn định trên dải SNR rộng (20-30 dB).

### 3.2. Cấu trúc Bộ cân bằng

Trong kiến trúc đề xuất, bộ cân bằng SVM hoạt động như một bộ phân loại đa lớp để khôi phục ký tự PAM-4. Thay vì nhận tín hiệu thô, SVM lấy đầu vào đã được xử lý bởi FFE. Đầu ra của FFE được đưa qua chuỗi bộ trễ, tạo vector đặc trưng đa chiều  $X_k = [x_k, x_{k-1}, \dots, x_{k-n+1}]^T$  với  $y_i$  là tín hiệu FFE tại thời điểm  $i$  và  $n$  là kích thước cửa sổ.



Hình 4. Minh họa cách đưa dữ liệu vào bộ cân bằng SVM thông qua các bộ trễ.

Chuỗi dữ liệu này sau đó được đưa vào bộ cân bằng SVM (Hình 4), nhờ kernel RBF, dữ liệu được ánh xạ sang không gian nhiều chiều, giúp mô hình học các quan hệ phi tuyến còn sót lại, nâng cao độ chính xác phân loại và giảm BER. Sự kết hợp FFE-SVM tận dụng ưu điểm của cả hai: FFE loại bỏ méo tuyến tính, trong khi SVM có nhiệm vụ xử lý các thành phần méo phi tuyến còn lại. Để giải quyết hiện tượng méo và nhiễu giữa các ký tự lân cận, đầu vào SVM được xây dựng bằng kỹ thuật cửa sổ trượt (sliding window), tạo thành vector đặc trưng gồm ký tự hiện tại và các ký tự trước đó. Bên cạnh đó, đầu ra được mã hóa One-Hot, đảm bảo tính độc lập giữa các lớp và tương thích với chiến lược OvR, từ đó cải thiện hiệu suất phân loại nhiều lớp của mô hình.

### 3.3. Chuẩn bị dữ liệu và kế hoạch khảo sát

#### a. Phân chia dữ liệu:

Tập dữ liệu gồm  $2^{18}$  ký tự PAM-4 (được tạo thành từ  $2^{19}$  bit với mỗi ký tự đại diện cho 2 bit). Mỗi mẫu dữ liệu gồm vector đặc trưng từ FFE (gồm  $n$  ký tự kề cận) và đầu ra là nhãn one-hot coding. Dữ liệu được chia thành 2 phần với tỉ lệ 75% cho huấn luyện và 25% cho kiểm tra. Để tránh việc rò rỉ thông tin, 2 tập dữ liệu này được thực hiện tách biệt có chủ đích nhằm đảm bảo không có sự chồng lấn về thông tin, có đệm giữa phần huấn luyện và kiểm tra. Kích bản 1 và 2, sử dụng 100.000 mẫu dữ liệu, trong khi Kích bản 3 thay đổi kích thước tập huấn luyện từ 10.000 – 200.000 để phân tích ảnh hưởng lên hiệu suất mô hình.

#### b. Tiền xử lý dữ liệu:

Đầu vào được chuẩn hóa bằng Standard Scaler theo z-score:

$$z = \frac{x - \mu}{\sigma} \quad (3)$$

với  $x$  là giá trị đặc trưng,  $\mu$  là giá trị trung bình của đặc trưng xét trên tập huấn luyện và  $\sigma$  độ lệch chuẩn của đặc trưng, phản ánh mức độ phân tán quanh  $\mu$ . Chuẩn hóa này giúp tất cả đặc trưng cùng thang đo, giảm sai lệch do chênh lệch quy mô, cải thiện khả năng học của SVM.

#### c. Kích bản khảo sát

- Khảo sát 1: Tối ưu siêu tham số  $C$  và  $\gamma$  của kernel RBF để lựa chọn tập tham số tối ưu. Các siêu tham số này được tối ưu bằng phương pháp tìm kiếm theo lưới trên tập huấn luyện với các giá trị  $C = \{0.1, 1, 10, 100\}$  và  $\gamma = \{0.01, 0.1, 1, 'scale'\}$ .
- Khảo sát 2: Với bộ tham số tối ưu, kiểm tra các chiều dài ngõ vào khác nhau (không sử dụng thông tin từ ký tự lân cận – input length = 1, và có sử dụng thông tin từ ký lân cận – input length = 2, 4, 6, 8) để xác định chiều dài hiệu quả, cân bằng giữa khả năng xử lý nhiễu/méo và độ phức tạp tính toán.
- Khảo sát 3: Huấn luyện với các kích thước tập dữ liệu khác nhau để xác định điểm bão hòa, khi việc tăng dữ liệu không còn cải thiện hiệu suất đáng kể.

## 4. KẾT QUẢ VÀ THẢO LUẬN

Để đánh giá hiệu suất bộ cân bằng SVM-RBF, chúng tôi sử dụng tỉ lệ lỗi bit BER (Bit Error Rate), được mô tả như sau:


$$BER = \frac{N_{error}}{N_{total}} \quad (4)$$

với  $N_{\text{error}}$  là số bit sai và  $N_{\text{total}}$  là tổng số bit truyền. Sau huấn luyện, mô hình thực hiện dự đoán ký tự trên tập kiểm tra đồng thời tính toán giá trị BER dưới nhiều điều kiện chất lượng tín hiệu khác nhau để làm tham chiếu đánh giá.

#### 4.1. Khảo sát vai trò của bộ cân bằng dựa trên SVM

Kịch bản khảo sát 1 bộ cân bằng SVM với kernel RBF trên toàn dải SNR (20-30 dB). Mục tiêu là xác định bộ siêu tham số ( $C, \gamma$ ) phù hợp. Với các giá trị khảo sát cụ thể như sau:  $C \in \{0.1, 1, 10, 50, 100\}$  và  $\gamma \in \{1, 0.1, 0.01, 'scale'\}$ .

Kết quả mô phỏng đã chỉ ra, so với bộ cân bằng tuyến tính FFE, nếu thiết lập các tham số phù hợp, mô hình SVM-RBF cho thấy hiệu suất vượt trội trong toàn bộ dải SNR được xét (Hình 5). Tại SNR = 22 dB, nhận thấy rằng mô hình FFE không thể đạt ngưỡng sửa lỗi FEC ( $3.8 \times 10^{-3}$ ). Tuy nhiên mô hình SVM-RBF với bộ tham số tối ưu  $C = 10, \gamma = scale$  có thể hỗ trợ cải thiện chất lượng tín hiệu và đạt dưới ngưỡng sửa lỗi ( $2.32 \times 10^{-3}$ ). Qua đó cho thấy việc ứng dụng kỹ thuật RBF-SVM có khả năng xử lý và cải thiện chất lượng tín hiệu khi so sánh với việc chỉ sử dụng bộ cân bằng tuyến tính FFE truyền thống. Cũng thấy rằng, việc ứng dụng SVM-RBF còn giúp tăng độ nhạy phía thu, cụ thể ở ngưỡng HD-FEC nhận thấy độ lợi SNR mang lại khoảng 1 dB khi so sánh với bộ cân bằng FFE và tăng lên đến xấp xỉ 2.5 dB khi xét tại ngưỡng BER =  $10^{-3}$ .



Hình 5. Vai trò của bộ cân bằng dựa trên kỹ thuật SVM được thiết lập với các tập thông số  $C, \gamma$  khác nhau.

Bên cạnh đó, quá trình khảo sát ảnh hưởng của các siêu tham số  $C$  và  $\gamma$  cho được một số xu hướng sau: Khi  $C$  tăng từ 0.1 lên 10, BER giảm rõ rệt, phản ánh lợi ích của việc tăng mức phạt đối với lỗi phân loại. Tuy nhiên, khi  $C = 50$  thì hiệu suất không cải thiện thêm mặc dù số lượng support vector tăng. Về  $\gamma$ , giá trị  $\gamma = scale$  mang lại hiệu suất cao nhất trên toàn dải SNR. Điều này cho thấy việc để  $\gamma$  tự động điều chỉnh (dựa trên độ


lệch chuẩn của dữ liệu) giúp mô hình tổng quát hóa và tương thích với các điều kiện kênh truyền khác nhau tốt hơn.

Từ các kết quả trên, bộ tham số  $C = 10, \gamma = scale$  sẽ được sử dụng trong các khảo sát tiếp theo nhằm hướng tới tối ưu hóa BER.

#### 4.2. Phân tích ảnh hưởng của chiều dài ngõ vào

Kịch bản khảo sát 2 nhằm xác định chiều dài ngõ vào tối ưu cho bộ cân bằng SVM-RBF, bảo đảm cân bằng giữa hiệu suất phân loại, độ trễ và độ phức tạp tính toán. Chiều dài ngõ vào (input length) thể hiện số mẫu tín hiệu lân cận được sử dụng khi dự đoán ký hiệu hiện tại. Chiều dài ngõ vào  $L$  được khảo sát với cả 2 trường hợp có/không có sử dụng thông tin từ ký tự lân cận,  $L \in 1, 2, 4, 6, 8$ .

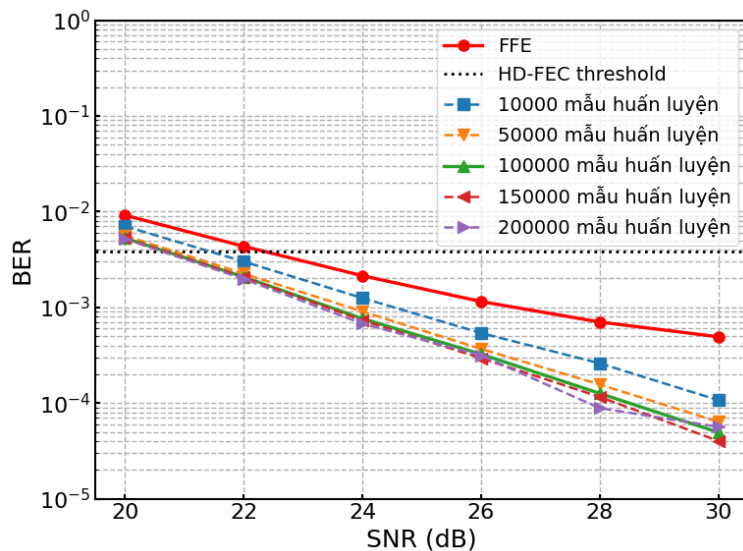
Kết quả khảo sát ở Hình 6 cho thấy được chiều dài ngõ vào ảnh hưởng trực tiếp đến khả năng xử lý tín hiệu của bộ cân bằng. Đầu tiên, với input length = 1 (sử dụng duy nhất ký hiệu hiện tại), mô hình không khai thác được thông tin từ các dữ liệu trước đó. Nhận thấy được rằng tỉ lệ lỗi bit BER gần như không có sự cải thiện đáng kể, quan sát được thông qua đường nét đứt màu đỏ (nhãn FFE) và đường nét đứt màu xanh da trời (nhãn SVM length=1) gần như trùng với nhau. Khi tăng chiều dài ngõ vào lên 2, 4 và 6, hiệu suất BER cải thiện rõ rệt, sự cải thiện khi tăng chiều dài ngõ vào cho thấy vai trò quan trọng của thông tin ký tự lân cận trong việc xử lý thông tin giữa các ký tự. Điều này cũng cho thấy rõ khả năng bù méo tín hiệu của mô hình RBF-SVM. Cụ thể, tại SNR = 22 dB, các cấu hình này giúp hệ thống hạ tỷ lệ BER xuống dưới ngưỡng FEC, điều này thể hiện việc khai thác thông tin từ các ký tự trước đó đã giúp mô hình xây dựng siêu mặt phẳng phân loại chính xác hơn trong không gian đặc trưng. Với input length = 8, nhận thấy rằng hiệu suất cải thiện BER gần như không tăng lên trên mọi khoảng xét, đơn cử ở SNR = 28 dB, length = 6 cho mức BER =  $1.8 \times 10^{-4}$  trong khi length = 8 là  $2.6 \times 10^{-4}$ . Điều này cho thấy mô hình đã đạt bão hòa, chiều dài ngõ vào với 4 hoặc 6 mẫu được xác định là tối ưu.



Hình 6. Ảnh hưởng của chiều dài ngõ vào đến hiệu quả của bộ cân bằng SVM.

### 4.3. Đánh giá hiệu quả với số lượng dữ liệu huấn luyện khác nhau

Kịch bản 3 được xây dựng nhằm đánh giá ảnh hưởng của kích thước tập huấn luyện đến hiệu suất BER. Mục tiêu là xác định liệu việc tăng dữ liệu huấn luyện có tiếp tục cải thiện BER hay không, đồng thời tìm ra ngưỡng tối thiểu của tập dữ liệu để đạt hiệu suất gần mức tối ưu, giúp cân bằng giữa chi phí thu thập dữ liệu và hiệu quả mô hình. SVM được cấu hình với  $C = 10$ ,  $\gamma = scale$  và chiều dài ngõ vào input length = 6. Kích thước dữ liệu huấn luyện được thay đổi từ  $10^3$  đến  $2 \times 10^5$  mẫu.



Hình 7. Ảnh hưởng của số lượng mẫu vào đến hiệu quả cải thiện BER.

Kết quả khảo sát số lượng mẫu huấn luyện cho thấy mối quan hệ rõ ràng giữa hiệu suất BER, quy mô dữ liệu và hiện tượng bão hòa (Hình 7). Khi tăng số mẫu, mô

hình học tốt hơn, giúp BER giảm đáng kể. Ví dụ, tại SNR = 28 dB, BER giảm từ  $2.6 \times 10^{-4}$  (10.000 mẫu) xuống  $1.56 \times 10^{-4}$  (50.000 mẫu), cho thấy lợi ích rõ rệt của việc mở rộng dữ liệu. Tuy nhiên, khi số mẫu đạt mức lớn, lợi ích bắt đầu giảm dần. Việc tăng từ 100.000 lên 150.000 mẫu, BER chỉ được cải thiện một lượng nhỏ (từ  $1.26 \times 10^{-4}$  xuống  $1.16 \times 10^{-4}$ ) và với 200.000 mẫu gần như không mang lại cải thiện về BER đáng kể, trong khi lại làm tăng khối lượng tính toán của mô hình.

Từ kết quả trên, quy mô dữ liệu huấn luyện tối ưu chỉ cần khoảng 50.000 mẫu đã có thể hỗ trợ cho mô hình học và đưa ra quyết định tốt, bên cạnh đó vẫn duy trì chi phí tính toán hợp lý. Do đó, 50.000-100.000 mẫu được xem là lựa chọn phù hợp cho triển khai thực tế.

#### 4. KẾT LUẬN

Nghiên cứu này đã trình bày ứng dụng bộ cân bằng phi tuyến dựa trên mô hình SVM với kernel RBF (SVM-RBF) cho hệ thống thông tin quang, cụ thể cho hệ thống cự ly ngắn với định dạng PAM-4 ở tốc độ 100 Gb/s sử dụng kỹ thuật IM/DD. Ba kịch bản khảo sát được triển khai giúp chúng ta có thể hình dung vai trò của các tham số/siêu tham số đến kết quả phân loại. Kết quả mô phỏng cho thấy, cấu hình với thiết lập  $C = 10$  và  $\gamma = scale$  mang lại BER tối ưu nhờ khả năng thích ứng tốt với phân bố dữ liệu hơn FFE trong nhiều điều kiện nhiễu khác nhau. Việc mở rộng chiều dài ngõ vào giúp giảm BER, nhưng hiệu quả nhất nên lựa chọn chiều dài ngõ vào với 4 hoặc 6 ký tự, vừa đảm bảo khả năng phân loại vừa hạn chế việc gây trễ xử lý. Ngoài ra, mô hình đạt hiệu quả cao nhất khi sử dụng 50.000-100.000 mẫu huấn luyện, sau ngưỡng này, BER chỉ giảm rất nhỏ cho thấy giới hạn học của SVM-RBF. Trên cơ sở đó, cấu hình tối ưu đề xuất gồm  $C = 10, \gamma = scale$ , chiều dài ngõ vào bằng 6 và bộ dữ liệu huấn luyện khoảng 100.000 mẫu, cho phép đạt BER thấp hơn FFE trên toàn bộ dải SNR khảo sát và đảm bảo độ phức tạp phù hợp cho triển khai thực tế. Trong tương lai, hướng phát triển có thể tập trung vào mở rộng mô hình cho các định dạng điều chế bậc cao hơn, tích hợp kỹ thuật giảm chiều hoặc lựa chọn đặc trưng để tối ưu chi phí tính toán, cũng như kết hợp SVM với các mô hình học sâu nhằm xây dựng bộ cân bằng lai hiệu năng cao cho hệ thống truyền dẫn tốc độ lớn.

#### LỜI CẢM ƠN

Bài báo này được hỗ trợ từ đề tài Khoa học và Công nghệ cấp Đại Học Huế, mã số đề tài DHH2025-01-229.

## TÀI LIỆU THAM KHẢO

- [1] Cisco. Cisco Visual Networking Index: Forecast and Trends, 2017–2022. White Paper. 2019.
- [2] Zhou H, Li Y, Liu Y, Yue L, Gao C, Li W, Qiu J, Guo H, Hong X, Zuo Y, Wu J. Recent advances in equalization technologies for short-reach optical links based on PAM4 modulation: a review. *Appl Sci.* 2019;9(11):2342.
- [3] Winzer PJ. Scaling Optical Fiber Networks: Challenges and Solutions. *Opt Photonics News.* 2015;26(3):28–35.
- [4] Agrawal GP. *Fiber-Optic Communication Systems*. 5th ed. Wiley; 2021.
- [5] Proakis JG, Salehi M. *Digital Communications*. 5th ed. McGraw-Hill; 2008.
- [6] Cortes C, Vapnik V. Support-vector networks. *Machine Learning.* 1995;20:273–297.
- [7] Shao C, Giacomidis E, Billah SM, Li S, Li J, Sahu P, Richter A, Faerber M, Kaefer T. Machine learning in short-reach optical systems: a comprehensive survey. *Photonics.* 2024;11(7):613.
- [8] Zhang J, Yan L, Jiang L, Yi A, Pan Y, Pan W, Luo B. Convolutional neural network equalizer for short-reach optical communication systems. *Asia Communications and Photonics Conference/International Conference on Information Photonics and Optical Communications 2020 (ACP/IPOC)*. OSA Technical Digest; 2020. p. M4A.320.
- [9] Dai X, Li X, Luo M, You Q, Yu S. LSTM networks enabled nonlinear equalization in 50-Gb/s PAM-4 transmission links. *Appl Opt.* 2019;58:6079–6084.
- [10] Xi Y, Bi M, Xin M, Yu J, Hu W, Wang C. Simplified SVM equalization algorithm based on single hyperplane training enabled 50Gb/s PAM-4/8 with 10-G optics in NG-PON system. *IEEE Photonics J.* 2021;13(4):1–7.
- [11] Chen G, Du J, Sun L, Zhang W, Xu K, Chen X, Reed GT, He Z. Nonlinear distortion mitigation by machine learning of SVM classification for PAM-4 and PAM-8 modulated optical interconnection. *J Lightwave Technol.* 2018;36(3):650–657.
- [12] Schölkopf B, Smola AJ. *Learning with Kernels*. MIT Press; 2002.
- [13] Shalev-Shwartz S, Ben-David S. *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press; 2014.
- [14] Da Ros F, Magalhães Ranzini S, Dischler R, Cem A, Aref V, Bülow H, Zibar D. Machine learning-based equalization for short-reach transmission: neural networks and reservoir computing. In: *Proceedings of SPIE*, Article 11712-2. SPIE; 2021.

## NONLINEAR SVM-BASED EQUALIZER FOR HIGH-SPEED SHORT-REACH IM/DD PAM-4 OPTICAL COMMUNICATION SYSTEMS

Vuong Quang Phuoc<sup>1\*</sup>, Nguyen Tan Hung<sup>2</sup>

<sup>1</sup> University of Sciences, Hue University

<sup>2</sup> Advanced Institute of Science and Technology, The University of Danang

\*Email: vqphuoc@hueuni.edu.vn

### ABSTRACT

In this paper, we present a nonlinear SVM-based equalizer for short-reach fiber-optic communication systems (FOCS) operating at 100 Gb/s with PAM-4 modulation. The proposed approach combines a linear Feed-Forward Equalizer (FFE) with a Support Vector Machine (SVM) classifier using a Radial Basis Function (RBF) kernel to reduce signal distortion caused by channel impairments and hardware limitations. The received signal is processed on a sequential basis using a sliding-window mechanism, normalized, and classified using a multi-class SVM structure with the One-vs-Rest technique. According to simulation results, the proposed equalizer outperforms the traditional FFE in terms of BER. The results demonstrate that the SVM-based equalizer proves to be an effective nonlinear equalization solution for next-generation optical systems.

**Keywords:** Equalization techniques, IM/DD, Nonlinear distortion, PAM-4, Support Vector Machine (SVM)