

## Giải pháp định vị trong nhà độ chính xác cao sử dụng thuật toán kNN và LSTM

Dương Thị Hằng<sup>1,2\*</sup>, Hoàng Mạnh Kha<sup>1</sup>, Trịnh Anh Vũ<sup>2</sup>, Phạm Thị Quỳnh Trang<sup>1</sup>

<sup>1</sup>Trường Đại học Công nghiệp Hà Nội, Minh Khai, Bắc Từ Liêm, Hà Nội;

<sup>2</sup>Trường Đại học Công nghệ, Đại học Quốc Gia Hà Nội, Xuân Thủy, Cầu Giấy, Hà Nội.

\*Email: hangdt@hau.edu.vn

Nhận bài: 15/02/2023; Hoàn thiện: 30/3/2023; Chấp nhận đăng: 10/4/2023; Xuất bản: 28/4/2023.

DOI: <https://doi.org/10.54939/1859-1043.j.mst.86.2023.48-55>

### TÓM TẮT

Bài báo trình bày một giải pháp hiệu quả cải thiện độ chính xác trong định vị trong nhà sử dụng học máy. Mục tiêu của giải pháp đề xuất là giảm sai số ước lượng khoảng cách bằng cách kết hợp hai thuật toán k láng giềng gần nhất (kNN) và bộ nhớ dài-ngắn hạn (LSTM). Kết quả mô phỏng cho thấy phương pháp tổng hợp của chúng tôi đạt được độ chính xác hơn 40% khi sai số yêu cầu nhỏ hơn 1 mét cao hơn so với độ chính xác 26% và 14% của các nghiên cứu khác sử dụng học máy trên cùng một tập dữ liệu và kịch bản mô phỏng tương tự

**Từ khoá:** Định vị trong nhà; Học máy; kNN; LSTM.

### 1. MỞ ĐẦU

Trong những năm gần đây, các dịch vụ dựa trên vị trí (LBS - Location based Service) đem lại những tiềm năng kinh tế to lớn và phục vụ được hầu hết các nhu cầu trong cuộc sống con người. Đây là một trong những lý do mà định vị trong nhà đã thu hút các nhà phát triển và các nhà nghiên cứu tập trung nguồn lực để cải thiện độ chính xác trong định vị trong nhà. Gần đây, do sự có mặt các điểm truy cập WiFi AP (Access Point) ở hầu hết các tòa nhà, văn phòng, khu công cộng nên các công nghệ định vị dựa trên RSSI (Receive Signal Strength Indicator) của tín hiệu WiFi ngày càng trở thành sự lựa chọn được ưu tiên trong lựa chọn dữ liệu để ước lượng vị trí cho bài toán định vị trong nhà. Kỹ thuật định vị nổi tiếng sử dụng RSSI WiFi là kỹ thuật dấu vân tay. Kỹ thuật này được chia làm hai giai đoạn đó là giai đoạn huấn luyện ngoại tuyến và định vị trực tuyến. Một số nghiên cứu điển hình trong những năm gần đây dùng tín hiệu WiFi sử dụng kỹ thuật học máy (Machine Learning - ML) để cải thiện hiệu quả trong định vị trong nhà được thực hiện trong nghiên cứu [2, 3]. Hiện nay, kỹ thuật học máy, đặc biệt là kỹ thuật học sâu đang được xem là một giải pháp tiềm năng cho nghiên cứu định vị trong nhà nhờ những lợi thế riêng của nó. Một trong những lợi thế quan trọng đó là khả năng học các đặc tính của đối tượng và có thể tìm ra những đặc trưng riêng, và khó nhầm lẫn với các đối tượng khác. Ngoài ra, các phương pháp học máy còn có khả năng đưa ra quyết định trong giai đoạn ước lượng trực tuyến từ các dữ liệu quan sát được mà không cần phải xây dựng công thức toán học phức tạp, tốn kém thời gian. Một số thuật toán học máy được đề xuất trong nhiều nghiên cứu trước đây áp dụng cho bài toán định vị [1, 4, 7, 9]. Trong một nghiên cứu khác sử dụng học sâu, các tác giả trong [9] đã đề xuất một thuật toán trích xuất tính năng, được gọi là bộ mã hóa tự động khử nhiễu xếp chồng đa tác vụ chung nhằm giảm kích thước của dữ liệu dấu vân tay ban đầu và cải thiện hiệu suất định vị trong nhà ở trung tâm mua sắm. Trong [10] các tác giả đã chỉ ra rằng, nếu chỉ sử dụng thuật toán kNN với dữ liệu thô thì độ chính xác không cao và các tác giả đã đề xuất một thuật toán kNN cải tiến. Nghiên cứu [5] chỉ ra rằng, nếu sử dụng kNN với hệ số k cố định sẽ đạt hiệu quả không cao, do đó các tác giả đã đưa ra giải pháp sử dụng kNN cải tiến với giá trị k thay đổi. Trong [8] sử dụng kết hợp hai thuật toán kNN và LSTM để ước lượng vị trí. Theo [8], kNN được sử dụng như là một thuật toán dự đoán vị trí trước sau đó kết quả này được đưa vào mô hình LSTM để huấn luyện. Với cách làm trong [8], chưa tận dụng được ưu điểm của kNN trong phân loại. Nếu sai số khi ước lượng vị trí dùng kNN lớn có thể gây ra sai số ước lượng vị trí của mô hình. Nhìn chung,

các giải pháp ứng dụng học máy cho bài toán định vị sử dụng tín hiệu WiFi còn tồn tại một số nhược điểm sau:

- Mô hình đạt được độ chính xác cao thì rất phức tạp khi triển khai và khối lượng tính toán lớn;
- Khi mô hình giảm độ phức tạp trong tính toán, giảm chi phí cũng như khả năng áp dụng thực tế thì độ chính xác không cao;

Thực tế cho thấy, việc xây dựng một mô hình giải quyết được đồng thời các nhược điểm trên của định vị trong nhà thực sự khó khăn. Chính vì thế, các nghiên cứu gần đây đã tiến hành cải tiến độ chính xác trong định vị tùy thuộc vào phạm vi ứng dụng của bài toán để đưa ra giải pháp phù hợp. Trong bài báo này, chúng tôi đề xuất giải pháp cải thiện độ chính xác trong định vị trong nhà sử dụng kết hợp thuật toán kNN và LSTM dùng tín hiệu WiFi.


Phần còn lại của bài báo này được trình bày như sau: Phần 2 trình bày cơ sở lý thuyết và các công trình liên quan. Phần 3 trình bày về kịch bản mô phỏng, tập dữ liệu được sử dụng cho bài báo, thảo luận kết quả và đánh giá hiệu suất của giải pháp đề xuất. Cuối cùng, Phần 4 là kết luận của bài báo.

## 2. CƠ SỞ LÝ THUYẾT

### 2.1. Thuật toán xác định vị trí dựa trên học máy

#### 2.1.1. K láng giềng gần nhất (kNN)


Thuật toán k láng giềng gần nhất là một thuật toán học máy và phân lớp có giám sát cơ bản nhất [6]. Thuật toán này sử dụng kết quả đo mức độ tương đồng để dự đoán giá trị của các điểm dữ liệu mới. Điều này có nghĩa là, điểm dữ liệu mới sẽ được phân loại vào một lớp đối tượng dựa trên mức độ tương đồng của nó với các điểm trong tập huấn luyện. Mức độ tương đồng giữa dữ liệu mới và dữ liệu huấn luyện có thể được tính toán bằng cách khoảng cách Euclide, Manhattan hoặc Hamming. Trong đó, khoảng cách đó là Euclide được sử dụng phổ biến nhất. Hình 1 biểu diễn khoảng cách giữa hai điểm trong không gian 2 chiều và công thức tính khoảng cách Euclid được biểu diễn theo công thức (1).




**Hình 1.** Khoảng cách giữa hai điểm trong không gian 2 chiều.

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \tag{1}$$

#### 2.1.2. Mô hình mạng học sâu bộ nhớ ngắn hạn định hướng dài hạn (LSTM)



**Hình 2.** Mô hình mạng LSTM cơ bản.



**Hình 3.** Cấu trúc tế bào LSTM [4].

Bộ nhớ dài-ngắn hạn (LSTM) được đề xuất lần đầu trong [4]. LSTM ra đời nhằm khắc phục được những hạn chế của RNN trước đây về hiện tượng triệt tiêu đạo hàm. Mạng LSTM bao gồm

nhều tế bào LSTM liên kết với nhau. Một tế bào LSTM bao gồm một ô nhớ, một cổng vào, một cổng ra và một cổng quên được mô tả trên hình 3. Ô nhớ có chức năng ghi nhớ các giá trị trong khoảng thời gian tùy ý và ba cổng điều chỉnh luồng thông tin vào và ra. Mô hình LSTM cơ bản được biểu diễn trên hình 2 [4].

Theo hình 3, các cổng trong một tế bào làm nhiệm vụ sàng lọc thông tin đầu vào và đầu ra được gọi là cổng quên  $f_t$ , cổng đầu vào  $i_t$  gồm các véc tơ  $x_t$  và cổng đầu ra  $o_t$  là các véc tơ  $y_t$ . LSTM khác với các mạng nơ ron kết nối đầy đủ và một số phương pháp học máy khác đó là mô hình này xử lý tuần tự các dữ liệu vào, ghi nhớ các thông tin bên trong tế bào LSTM, có khả năng quên các trạng thái không quan trọng. Do đó, khi sử dụng mô hình LSTM sẽ giảm được khối lượng tính toán so với các mô hình kết nối đầy đủ. Tế bào LSTM chịu trách nhiệm duy trì thông tin được trích xuất từ thời điểm cũ để đưa ra mối liên hệ với các thông tin tại thời điểm hiện tại. Theo đó, trạng thái trong  $c_t$  đóng vai trò của bộ nhớ dài hạn còn các trạng thái  $h_t$  đóng vai trò như bộ nhớ ngắn hạn trong tế bào LSTM.

Xét tại thời điểm  $t$ , gọi  $i_t$  là các đầu vào ở trạng thái hiện tại,  $o_t$  là các đầu ra và  $f_t$  là các cổng quên. Các hàm kích hoạt được sử dụng cho cổng quên và ô nhớ là hàm sigmoid và hàm tanh được biểu diễn lần lượt trên (2) và (3) đại diện cho cổng quên và ô nhớ thông tin trong tế bào LSTM.

$$\sigma_g(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$\sigma_h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

Cổng quên sẽ đưa ra quyết định thông tin nào được giữ lại hoặc loại bỏ. Cổng quên được biểu diễn theo (4)

$$f_t = \sigma(\mathbf{W}_f x_t + \mathbf{U}_f h_{t-1} + b_f) \quad (4)$$

Thông tin được coi như không quan trọng nếu  $f_t$  gần với 0 và bộ nhớ tế bào LSTM sẽ bỏ qua thông tin này. Nếu  $f_t$  gần với 1 có nghĩa thông tin này quan trọng và được truyền đi.

Cổng vào được biểu diễn theo (5). Cổng đầu vào làm nhiệm vụ xác định thông tin mới nào sẽ được lưu trữ trong ô nhớ LSTM. Sau đó, một lớp tanh sẽ tạo ra một véc tơ các giá trị mới có khả năng thêm vào các trạng thái tiếp theo của ô nhớ.

$$i_t = \sigma_g(\mathbf{W}_i x_t + \mathbf{U}_i h_{t-1} + b_i) \quad (5)$$

Cổng ra được biểu diễn theo (6):

$$o_t = \sigma_g(\mathbf{W}_o x_t + \mathbf{U}_o h_{t-1} + b_o) \quad (6)$$

Khi đó, các trạng thái sẽ được tế bào LSTM ghi nhớ thông qua (7)

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \sigma_h(\mathbf{W}_c x_t + \mathbf{U}_c h_{t-1} + b_c) \quad (7)$$

Đầu ra của mô hình được xác định theo (8)

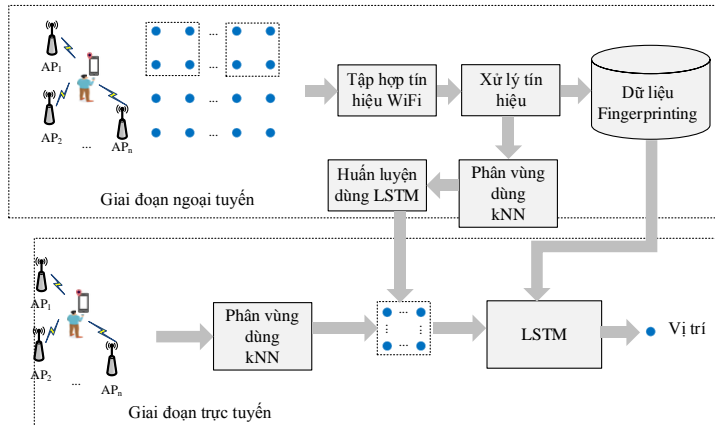
$$h_t = o_t \cdot \sigma_h(c_t) \quad (8)$$

Trong đó,  $h_{t-1}$  là trạng thái ẩn của thời điểm trước,  $x_t$  là đầu vào hiện tại,  $\mathbf{W}$ ,  $\mathbf{U}$  là các ma trận trọng số và  $b$  là giá trị hiệu chỉnh,  $c_t$  là ô nhớ của tế bào LSTM.

## 2.2. Mô hình đề xuất

Để đánh giá hiệu quả của giải pháp đề xuất với các nghiên cứu sử dụng học máy khác chúng tôi sử dụng cùng tập dữ liệu với [2, 3]. Sơ đồ khối tổng quát mô hình đề xuất biểu diễn trên hình 4.


Trong mô hình này chúng tôi sử dụng kNN để phân vùng đối tượng nhằm khoanh vùng đối tượng theo vị trí trong không gian định vị. Đầu ra của mô hình kNN đóng vai trò là đầu vào của mô hình huấn luyện sử dụng LSTM. Tại mỗi một vị trí tham chiếu trong giai đoạn huấn luyện, toàn bộ dữ liệu thu được từ các AP đều được sử dụng mà không loại bỏ bất kỳ giá trị nào. Việc không loại bỏ các AP mà RSSI không thu được tại mỗi vị trí tham chiếu là do đây cũng là một đặc điểm riêng để phân biệt các vị trí khác nhau trong bản đồ định vị.



**Hình 4.** Sơ đồ khối mô hình đề xuất.

**2.3. Thuật toán đề xuất**

Hình 5 mô tả kiến trúc của mô hình đề xuất kết hợp kNN và LSTM. Lớp đầu vào gồm N đặc trưng là các giá trị RSSI của các điểm truy cập AP<sub>1</sub> đến AP<sub>N</sub> và một số đặc trưng mở rộng và đầu ra của mô hình phân loại kNN. Để ngăn chặn trạng thái học quá mức, một lớp bỏ học được thêm vào lớp LSTM với tỉ lệ bỏ học là 0.3. Sau đó, kết quả từ lớp LSTM sẽ được đưa vào một lớp kết nối đầy đủ bao gồm 110 tế bào nơ ron. Tầng cuối cùng là lớp ra gồm 2 nơ ron đại diện cho tọa độ tương ứng với vị trí của đối tượng.



**Hình 5.** Kiến trúc mô hình đề xuất.

Giả sử các véc tơ đầu vào của mô hình là

$$\{r^i(t)\}_{i=1}^N$$

bao gồm các giá trị RSSI thu được từ các điểm truy cập WiFi, các đặc trưng mở rộng EF (Extra Feature). Các đặc trưng mở rộng này được sinh ra dựa trên dữ liệu RSSI thu được tại mỗi vị trí tham chiếu. Trong giai đoạn phân loại, mô hình kNN sử dụng các dữ liệu này để phân vùng đối tượng theo thuật toán 1.

**Thuật toán 1: Thuật toán phân vùng dùng kNN**

**Đầu vào:** D – Tập huấn luyện.  $X = \{RSSI, EF\}_{i=1}^{N_{train}}$

$m$  số vùng được phân loại

**Đầu ra :** Dự đoán dùng kNN

Sử dụng công thức (1) để tìm  $k$  điểm trong bản đồ định vị có khoảng cách gần nhất với giá trị cần dự đoán trong vùng  $m$  để dự đoán đầu ra kNN

$$Y_{outkNN} = kNN(X, label)$$

Sau khi phân vùng cho đối tượng dùng kNN, đầu ra của mô hình này được đưa vào đầu vào của mô hình ước lượng vị trí dùng LSTM. Ước lượng vị trí theo giải pháp đề xuất được trình bày trên thuật toán 2. Trong đó, các ký hiệu  $X_{train}, X_{val}, X_{test}$  là các đại lượng đại diện cho dữ liệu đầu vào huấn luyện, đầu vào kiểm thử validation và đầu vào ước lượng trực tuyến.  $N_{train}, N_{val}, N_{test}$  là số mẫu trong tập huấn luyện, tập kiểm thử validation và tập ước lượng trực tuyến.  $D_{train}, D_{val}$  lần lượt là tập dữ liệu của giai đoạn huấn luyện và giai đoạn kiểm thử validation.  $Y_{train}, Y_{val}$  lần lượt là đầu ra trong giai đoạn huấn luyện và kiểm thử validation.  $E_{Y_{val}}(X_{val}, Y_{val})$  và  $E_{Y_t}(X_t^k, Y_{true}^k)$  là sai số giữa giá trị ước lượng và giá trị thực trong giai đoạn kiểm thử.  $\hat{Y}_{outkNN}$  là đầu ra ước lượng trong giai đoạn trực tuyến của kỹ thuật kNN.  $\{\hat{Y}_{est}\}$  là đầu ra ước lượng vị trí dùng LSTM.

---

**Thuật toán 2: Thuật toán LSTM cho ước lượng vị trí**

---

**Đầu vào:** Các véc tơ  $\{X_{train}\}_{i=1}^{N_{train}} = \{r^i(t), \hat{Y}_{outkNN}\}_{i=1}^{N_{train}}$ ,  $\{X_{val}\}_{i=1}^{N_{val}} = \{r^i(t), \hat{Y}_{outkNN}\}_{i=1}^{N_{val}}$ ,

$$Y_{train} = \left\{ \left( x^i, y^i \right) \right\}_{i=1}^{N_{train}} \quad Y_{val} = \left\{ \left( x^i, y^i \right) \right\}_{i=1}^{N_{val}}$$

**Khởi tạo giá trị ban đầu cho mô hình:** epoch = 500.

**Tạo tập dữ liệu :** Dữ liệu huấn luyện  $D_{train} = \{X_{train}, Y_{train}\}$  và dữ liệu kiểm thử

$$D_{val} = \{X_{val}, Y_{val}\}$$

Lặp với số lần lặp xác định:

Duyệt tất cả các phần tử trong tập huấn luyện  $(X_{train}^k, Y_{train}^k)$  in  $D_{train}$

$$\hat{Y}_{est}^k = LSTM(X_t^k, \mathbf{W}^{k-1})$$

$$E_{Y_t}(X_t^k, Y_t^k) = \left\| \hat{Y}_{est}^k - Y_{true}^k \right\|$$

Cập nhật trọng số  $\mathbf{W}^k$

Kết thúc vòng lặp khi duyệt các phần tử trong  $D_{train}$

Đánh giá hiệu quả của mô hình mạng trên tập thử nghiệm Validation  $D_{val} = \{X_{val}, Y_{val}\}$

Lặp và kiểm tra tất cả các giá trị  $(X_{val}, Y_{val})$  có trong  $D_{val}$

$$E_{Y_{val}}(X_{val}, Y_{val}) = \left\| LSTM(X_{val}, \mathbf{W}) - Y_{val} \right\|$$

Kết thúc vòng lặp kiểm tra trong  $D_{val}$

Kết thúc vòng lặp chương trình

**Đầu ra:** Mô hình suy hao giữa giá trị huấn luyện và giá trị kiểm thử (Validation).

Trọng số  $\mathbf{W}$  của mô hình

**Ước lượng trực tuyến:**

Dữ liệu mới thu được trong giai đoạn trực tuyến là véc tơ có dạng  $X = \{RSSI_i\}_{i=1}^N$  từ một vị trí

$$Y_{true} = \left\{ \left( x_0^i, y_0^i \right) \right\}_{i=1}^N. \text{ Vị trí mới được dự đoán } \left\{ \hat{Y}_{est} \right\}_{i=1}^N = LSTM(X, \mathbf{W})$$


---

### 3. MÔ PHỎNG, TÍNH TOÁN, THẢO LUẬN

#### 3.1. Tập dữ liệu đầu vào

Để đảm bảo tính công bằng khi so sánh giải pháp đề xuất với một số giải pháp học máy khác, chúng tôi sử dụng cùng một bộ dữ liệu khi đánh giá hiệu quả ước lượng vị trí với các nghiên cứu [2, 3]. Mô tả chi tiết về cách thu thập dữ liệu được trình bày trong [3]. Các giá trị RSSI được thu

thập ở 25 vị trí khác nhau tại cùng một tầng trong một tòa nhà văn phòng, khoảng cách trung bình giữa hai vị trí tham chiếu lân cận là 2.7 m. Người thu thập dữ liệu thực hiện 100 phép đo theo 4 hướng  $0^0, 90^0, 180^0$  và  $270^0$ , tương ứng 25 mẫu tại một hướng tại mỗi vị trí vào các thời điểm khác nhau trong ngày. Tổng số AP xuất hiện trong tập dữ liệu thu thập được là 60. Như vậy, tập dữ liệu bao gồm 5000 véc tơ đại diện cho 5000 phép đo sử dụng cho cả quá trình huấn luyện ngoại tuyến và thử nghiệm trực tuyến. Khi thực hiện mô phỏng, 80% dữ liệu tương ứng với 4000 mẫu được dùng cho quá trình huấn luyện và 20% dữ liệu tương ứng với 1000 mẫu được dành cho giai đoạn thử nghiệm. Trong [3] các tác giả sử dụng toàn bộ RSSI thu được từ các AP cho đầu vào huấn luyện. Trong [2] các tác giả lựa chọn các AP có cường độ tín hiệu thu được lớn nhất để làm đầu vào huấn luyện trong giai đoạn ngoại tuyến. Trong giai đoạn ước lượng trực tuyến, các tác giả trong [3] và [2] sử dụng tương ứng 5 mẫu và 12 mẫu cho mỗi lần ước lượng vị trí. Với các thiết bị điện thoại thông minh, chu kỳ để có thể cập nhật được dữ liệu RSSI mới là khoảng 1-1.5 giây. Như vậy, việc sử dụng 5 hoặc 12 mẫu dữ liệu cho mỗi lần định vị khó có thể đáp ứng được yêu cầu định vị cho đối tượng di chuyển thường xuyên. Vì vậy, nghiên cứu này chỉ sử dụng 1 mẫu cho mỗi lần ước lượng vị trí nhằm đảm bảo thời gian xử lý định vị đủ đáp ứng cho các yêu cầu thực tiễn. Bảng 1 mô tả cấu trúc dữ liệu đầu vào.

**Bảng 1.** Cấu trúc dữ liệu vào của hệ thống.

	AP1	AP2	AP3	AP4	AP5	...	AP60	EF1	EF2	...	EF8	LAT	LONG	Pos
1	-69	-69	-69	No.	-100	...	-100	-69	-88.2	...	3.868718422	51.70891	8.767863	1
2	-73	-72	-72	-72	-100	...	-100	-72	-88.9	...	4.522180971	51.70891	8.767863	1
3	-73	-75	-72	-77	-100	...	-100	-72	-89.7	...	4.640360671	51.70891	8.767863	1
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
5000	-88	-89	-88	-75	-100	...	-100	-75	-96.55	...	5.396463552	51.70912	8.767772	25

Các đặc trưng mở rộng được tạo ra dựa trên đặc điểm dữ liệu thu thập. Cách tạo ra các đặc trưng mở rộng được trình bày trên bảng 2.

**Bảng 2.** Các đặc trưng mở rộng.

Tên	Ý nghĩa	Tên	Ý nghĩa
<b>F1</b>	$\text{Max}(\{RSSI\}_{i=1}^{N_{AP}})$ Giá trị RSSI lớn nhất thu được tại mỗi vị trí	<b>F5</b>	$\text{Average}(\{RSSI\}_{i=1}^{N_{AP}})$ Trung bình các giá trị RSSI trên tập dữ liệu
<b>F2</b>	$\text{Average}(\{RSSI\}_{i=1}^{10})$ Trung bình các giá trị RSSI trên AP1 đến AP10	<b>F6</b>	$\text{Average}(\{RSSI\}_{i=1}^{20})$ Trung bình các giá trị RSSI trên AP1 đến AP20
<b>F3</b>	$\text{Min}(\{RSSI\}_{i=1}^{N_{AP}})$ $\text{Max}(\{RSSI\}_{i=1}^{N_{AP}})$ Hiệu giữa giá trị RSSI nhỏ nhất và giá trị RSSI lớn nhất thu được tại mỗi vị trí.	<b>F7</b>	$\text{Average}(\{RSSI\}_{i=40}^{60})$ Trung bình các giá trị RSSI trên AP40 đến AP60
<b>F4</b>	$\text{Kurt}(\{RSSI\}_{i=1}^{N_{AP}})$ Biểu diễn phân bố của dữ liệu RSSI	<b>F8</b>	$\text{Skew}(\{RSSI\}_{i=1}^{N_{AP}})$ Độ lệch của phân bố RSSI trên tập dữ liệu

Theo bảng 1, dữ liệu vào của mô hình đề xuất gồm N (N = 60) giá trị RSSI từ các điểm truy cập Access Point -AP. Chúng tôi bổ sung thêm  $N_{EF}$  các đặc trưng mở rộng ( $N_{EF} = 8$ , EF-Extra Feature) theo bảng 2. Tọa độ của vị trí đối tượng theo vĩ độ và kinh độ (Latitude và Longitude). Pos là thứ tự vị trí của đối tượng khi phân vùng dữ liệu.


### 3.2. Mô phỏng và thảo luận

Mục tiêu của bài toán định vị trong nhà là giảm tối đa lỗi khoảng cách giữa vị trí thực và vị trí ước lượng. Vì vậy, để đánh giá hiệu quả của giải pháp đề xuất chúng tôi sử dụng công thức tính

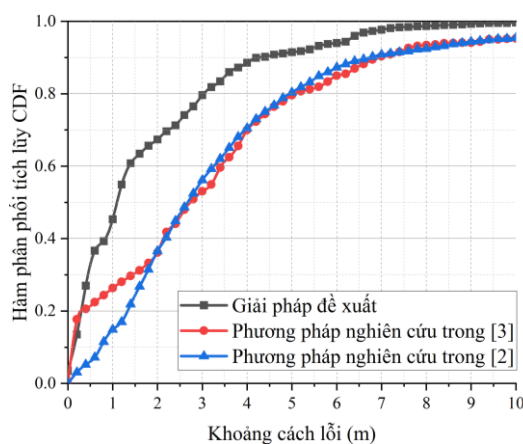
lỗi tuyệt đối trung bình MAE (Mean Absolute Error) theo (9):

$$MAE = \frac{1}{S} \sum_{i=1}^S |\hat{Y}_{est} - Y_{true}| \quad (9)$$

Trong đó,  $\hat{Y}_{est}, Y_{true}$  lần lượt là các giá trị vị trí ước lượng và giá trị vị trí thực của đối tượng, S là số mẫu khi ước lượng.



**Hình 6.** Mô hình suy hao.



**Hình 7.** Hàm phân phối tích lũy sai số khoảng cách.

Có hai kỹ thuật định vị khác nhau được lựa chọn để so sánh hiệu suất với giải pháp đề xuất của chúng tôi. Các kỹ thuật này được trình bày chi tiết trong [2, 3]. Sự hội tụ và tốc độ của mô hình đề xuất là thước đo để đánh giá hiệu suất của nó. Hình 6 biểu diễn mối quan hệ giữa sai số bình phương trung bình của suy hao giữa dữ liệu huấn luyện và dữ liệu kiểm thử của mô hình đề xuất. Theo đó, tại vị trí epoch có giá trị 500 thì mô hình đạt được độ hội tụ tốt, khi epoch tăng lên thì độ bám sát của giá trị kiểm thử và giá trị thực tăng lên không đáng kể. Do đó, khi ước lượng, chúng tôi chọn tham số epoch = 500. Để đánh giá hiệu suất của hệ thống đề xuất, chúng tôi thử nghiệm bằng cách tính toán giá trị lỗi tuyệt đối trung bình, tính khoảng cách lỗi định vị. Hàm phân phối tích lũy (CDF) được sử dụng để đánh giá hiệu suất của giải pháp đề xuất khi ước lượng vị trí. Hàm này biểu diễn xác suất ước lượng vị trí với sai số khoảng cách trong phạm vi từ 0 đến 10m. Hình 7, mô tả hàm phân phối tích lũy cho các sai số khoảng cách định vị tương ứng với các giải pháp khác nhau.

Theo đó, trong khoảng lỗi từ 0 đến 10m giải pháp đề xuất đạt được độ chính xác cao hơn so với [2, 3]. Trong phạm vi lỗi từ 0 đến 0.2m, giải pháp của chúng tôi đạt độ chính xác tương đương so với phương pháp nghiên cứu [3] và cao hơn so với nghiên cứu [2]. Tuy nhiên, với khoảng sai số định vị nhỏ hơn 1m thì giải pháp của chúng tôi đạt độ chính xác hơn 40%, trong khi đó, độ chính xác này là 26% và 14% lần lượt với [2, 3]. Đặc biệt khi độ chính xác yêu cầu nhỏ hơn hoặc bằng 2m thì giải pháp đề xuất của chúng tôi đạt hiệu quả vượt trội là hơn 60% trong khi các giải pháp còn lại có độ chính xác đạt gần 40%.

#### 4. KẾT LUẬN

Dựa vào khả năng học sâu và lưu trữ các trạng thái của thuật toán LSTM và khả năng phân vùng dữ liệu của kNN mà nhóm tác giả đã kết hợp hai thuật toán này để giảm lỗi ước lượng vị trí trong nhà dùng tín hiệu WiFi. Hiệu quả vượt trội của giải pháp đề xuất thể hiện rõ tại hầu hết các khoảng cách lỗi định vị bằng hàm phân phối tích lũy so với các phương pháp khác trên cùng tập dữ liệu và cùng kích bản mô phỏng. Kết quả nghiên cứu cho thấy rằng, việc sử dụng kết hợp các

kỹ thuật học máy và tận dụng ưu điểm của riêng từng kỹ thuật đơn lẻ đem lại hiệu quả cao trong bài toán định vị trong nhà.

### TÀI LIỆU THAM KHẢO

- [1]. Dong, Y., Arslan, T., and Yang, Y., "An Encoded LSTM Network Model for WiFi-based Indoor Positioning", 2022 IEEE 12th International Conference on Indoor Positioning and Indoor Navigation (IPIN), pp. 1-6, (2022).
- [2]. Hoang, Kha, Vu, Kien, "Performance Enhancement of Wi-Fi Fingerprinting-Based IPS by Accurate Parameter Estimation of Censored and Dropped Data", *Radioengineering*, 28, p. 741, (2019).
- [3]. Hoang, M. K. and Haeb-Umbach, R., "Parameter estimation and classification of censored Gaussian data with application to WiFi indoor positioning", 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 3721-3725, (2013).
- [4]. Hochreiter, Sepp and Schmidhuber, Jürgen, "Long Short-Term Memory", *Neural Computation*, 9(8), pp. 1735-1780, (1997).
- [5]. Mosleh, Mahmood, Abd-Alhameed, Raed, and Qasim, Osama, "Indoor Positioning Using Adaptive KNN Algorithm Based Fingerprint Technique": 9th International EAI Conference, Broadnets 2018, Faro, Portugal, September 19–20, 2018, Proceedings", pp. 13-21, (2019).
- [6]. Peterson, Leif, "K-nearest neighbor", *Scholarpedia*, 4, p. 1883, (2009).
- [7]. Roy, Priya and Chowdhury, Chandreyee, "A Survey of Machine Learning Techniques for Indoor Localization and Navigation Systems", *Journal of Intelligent & Robotic Systems*, 101, (2021).
- [8]. Thenuardi, Dionisius and Soewito, Benfano, "Indoor Positioning System using WKNN and LSTM Combined via Ensemble Learning", *Advances in Science, Technology and Engineering Systems Journal*, 6, pp. 242-249, (2020).
- [9]. Zhang, H., et al., "Feature Fusion Using Stacked Denoising Auto-Encoder and GBDT for Wi-Fi Fingerprint-Based Indoor Positioning", *IEEE Access*, 8, pp. 114741-114751, (2020).
- [10]. Zhu, Xuanyu, "Indoor Localization Based on Optimized KNN", *Network and Communication Technologies*, 5, p. 34, (2020).

### ABSTRACT

#### **High accuracy indoor positioning approach using kNN and LSTM algorithms**

*In this paper, an effective approach to improve indoor positioning accuracy using machine learning is presented. The goal of the proposed solution is to reduce the distance estimation error by combining two algorithms k Nearest Neighbor (kNN) and Long Short-Term Memory (LSTM). Simulation results show that our solution achieves an accuracy of 40% when the required error is less than 1 meter, is higher than 26% and 14%, which respectively, of other studies using machine learning on the same data set and similar simulation scenarios.*

**Keywords:** Indoor Positioning System; Machine Learning; kNN; LSTM.