

**ĐẠI HỌC QUỐC GIA TP. HỒ CHÍ MINH
TRƯỜNG ĐẠI HỌC BÁCH KHOA**

ĐẶNG NGUYỄN CHÂU

**PHƯƠNG PHÁP NHẬN DẠNG KHUÔN MẶT TRONG ĐIỀU KIỆN
ĐƠN MẪU DỰA TRÊN ĐỘ ĐO LT-MHD**

Ngành: Kỹ thuật Viễn thông
Mã số ngành: 62520208

TÓM TẮT LUẬN ÁN TIẾN SĨ

TP. HỒ CHÍ MINH - NĂM 2021

Công trình được hoàn thành tại **Trường Đại học Bách Khoa – ĐHQG-HCM**

Người hướng dẫn: PGS. TS. Đỗ Hồng Tuấn

Phản biện độc lập:

Phản biện độc lập:

Phản biện:

Phản biện:

Phản biện:

L luận án sẽ được bảo vệ trước Hội đồng đánh giá luận án họp tại

.....

.....

vào lúc giờ ngày tháng năm

Có thể tìm hiểu luận án tại thư viện:

- Thư viện Trường Đại học Bách Khoa – ĐHQG-HCM
- Thư viện Đại học Quốc gia Tp.HCM
- Thư viện Khoa học Tổng hợp Tp.HCM

CHƯƠNG 1 GIỚI THIỆU

Nhận dạng khuôn mặt và điều kiện SSPP trong nhận dạng khuôn mặt

Trong những năm qua, đã có rất nhiều các phương pháp nhận dạng khuôn mặt được đề xuất với các kết quả rất đáng khích lệ. Tuy nhiên, lĩnh vực nhận dạng khuôn mặt vẫn còn rất nhiều bài toán cần được giải quyết, trong đó bài toán lớn nhất là tỷ lệ nhận dạng của các phương pháp suy giảm rất nhiều trong điều kiện chỉ có một ảnh cho mỗi cá nhân trong cơ sở dữ liệu. Đây chính là điều kiện SSPP (Single sample per person) trong nghiên cứu nhận dạng khuôn mặt. Điều kiện SSPP là một điều kiện ràng buộc trong rất nhiều các ứng dụng thực tế về nhận dạng khuôn mặt. Đã có rất nhiều nghiên cứu được đề xuất để giải quyết bài toán SSPP trong nhận dạng khuôn mặt. Các nghiên cứu này có thể chia thành 04 nhóm: nhóm các phương pháp nhận dạng dựa trên đặc trưng toàn cục của ảnh, nhóm các phương pháp nhận dạng dựa trên đặc trưng cục bộ của ảnh, nhóm phương pháp tạo ra thêm ảnh ảo và nhóm phương pháp sử dụng thêm một tập chung.

Lý do chọn đề tài

Theo các nghiên cứu, không có nhóm phương pháp nào nổi trội hơn so với các nhóm phương pháp còn lại [9-10]. Nhóm phương pháp nhận dạng khuôn mặt dựa trên đặc trưng cục bộ được các nghiên cứu đánh giá là dễ dàng triển khai trong các ứng dụng thực tế. Trong số các đặc trưng cục bộ, các pixel cạnh là một đặc trưng cục bộ được khá nhiều các phương pháp trong nhóm này sử dụng vì ưu điểm bền vững với những điều kiện khác nhau của ảnh đầu vào, nhất là điều kiện về ánh sáng. Các phương pháp này [15-24] sử dụng khoảng cách Hausdorff trung bình để đo sự giống nhau giữa hai tập hợp các pixel cạnh hoặc các điểm trội trong số các pixel cạnh. Nhược điểm của nhóm phương pháp này là tỷ lệ nhận dạng chưa thật sự tốt và độ phức tạp tính toán rất cao. Điều này chính là rào cản để có thể áp dụng các phương pháp nhận dạng khuôn mặt [15-24] này vào các ứng dụng thực tế. Như vậy, một nghiên cứu để đưa ra giải pháp giảm độ phức tạp tính

toán đồng thời nâng cao tỷ lệ nhận dạng chính xác cho các phương pháp này là một nghiên cứu rất cần thiết.

Mục tiêu và các đóng góp chính của đề tài

Trong nghiên cứu này, một khoảng cách mới được đề xuất để đo khoảng cách giữa các tập hợp đặc trưng, khoảng cách Least Trimmed-Modified Hausdorff distance (LT-MHD). Dựa trên khoảng cách LT-MHD, hai phương pháp nhận dạng khuôn mặt trong điều kiện SSPP được đề xuất: phương pháp Least Trimmed-New Modified Hausdorff distance (LT-MMHD), là cải tiến của phương pháp MMHD [23] và phương pháp Least Trimmed-Line Hausdorff distance (LT-LHD), là cải tiến của phương pháp LHD [24]. Thông hai phương pháp LT-MMHD và phương pháp LT-LHD, nghiên cứu sẽ chứng minh việc dùng khoảng cách LT-MHD thay cho khoảng cách Hausdorff trung bình sẽ giúp làm tăng tỷ lệ nhận dạng của các phương pháp nhận dạng khuôn mặt. Đồng thời, nghiên cứu cũng chứng minh khoảng cách LT-MHD có thể được sử dụng hiệu quả để đo khoảng cách giữa hai tập hợp của những loại đặc trưng khác nhau của ảnh khuôn mặt. Các kết quả này cũng có thể được mở rộng để giúp cải thiện tỷ lệ nhận dạng cho các phương pháp tương tự trong nhóm [15-22]. Bên cạnh đó, nghiên cứu này cũng đưa ra một giải pháp để giảm độ phức tạp tính toán cho hai phương pháp LT-MMHD và phương pháp LT-LHD. Hai nghiên cứu nổi tiếng trong lĩnh vực CAD/CAM để giảm độ phức tạp phép tính khoảng cách Hausdorff là EARLYBREAK và LSS sẽ được áp dụng để làm giảm độ phức tạp cho các phương pháp LT-MMHD và phương pháp LT-LHD. Nếu giải pháp này cho thấy sự hiệu quả trong việc giảm độ phức tạp cho các phương pháp LT-MMHD và phương pháp LT-LHD thì cũng có thể được mở rộng để áp dụng cho các phương pháp khác [15-22]. Ngoài ra, trong phần cuối của nghiên cứu này, chúng tôi cũng trình bày một phương pháp trích đặc trưng ảnh khuôn mặt bằng cách áp dụng một mạng CNN, trong đó khoảng cách LT-MHD được sử dụng như hàm mất mát của mạng này.

Nội dung và những đóng góp chính của luận án có thể được tóm tắt như sau:

- Đề xuất một khoảng cách mới LT-MHD. Dựa trên khoảng cách LT-MHD đề xuất hai phương pháp nhận dạng khuôn mặt trong điều kiện SSPP: LT-MMHD và LT-LHD. Thông qua kết quả mô phỏng tỷ lệ nhận dạng của hai phương pháp LT-MMHD và LT-LHD chứng minh được sử dụng khoảng cách LT-MHD thay cho khoảng cách Hausdorff trung bình giúp cải thiện 2-10% tỷ lệ nhận dạng của các phương pháp. Các kết quả cũng chứng minh việc sử dụng khoảng cách LT-MHD đem lại hiệu quả với nhiều loại đặc trưng khác nhau của ảnh khuôn mặt.
- Hai phương pháp LT-MMHD và LT-LHD cho kết quả khá tốt khi được so sánh với các phương pháp nhận dạng khuôn mặt trong điều kiện SSPP trong những năm gần đây. Đặc biệt, phương pháp LT-LHD có tỷ lệ nhận dạng cao hơn 2-11% so với các phương pháp được đề xuất trong khoảng 5 năm gần đây.
- Phương pháp LT-MMHD có độ phức tạp tính toán và thời gian tính toán thấp hơn phương pháp MMHD lần lượt là 17% và 16%. Tương tự, phương pháp LT-LHD có độ phức tạp tính toán và thời gian tính toán thấp hơn phương pháp LHD lần lượt là 67% và 65%. Điều này chứng minh sự hiệu quả trong việc giảm độ phức tạp tính toán của các phương pháp nhận dạng khuôn mặt khi áp dụng các phương pháp như EARLYBREAK và LSS.
- Đề xuất một mô hình trích đặc trưng ảnh khuôn mặt trong điều kiện SSPP dựa trên việc kết hợp một mạng CNN cùng khoảng cách LT-MHD. Việc sử dụng khoảng cách LT-MHD làm hàm mất mát của mạng CNN thay cho hàm crossentropy giúp làm tăng tỷ lệ nhận dạng 43%.
- Các kết quả của nghiên cứu được công bố trong 2 bài báo tạp chí quốc tế, 3 bài báo tạp chí trong nước, 1 hội nghị quốc tế chuyên ngành.

Phần còn lại của luận án được trình bày như sau: Chương 2 trình bày về khảo sát một số nghiên cứu gần đây về nhận dạng khuôn mặt trong điều kiện SSPP. Bên cạnh đó các nghiên cứu giúp làm giảm độ phức tạp tính toán của khoảng cách

Hausdorff cũng được trình bày trong chương này. Chương 3 trình bày về phép đo LT-MHD và phương pháp LT-MMHD cho nhận dạng khuôn mặt. Chương 4 trình bày về phương pháp LT-LHD cho nhận dạng khuôn mặt. Các kết quả mô phỏng cho phương pháp LT-MMHD và LT-LHD được trình bày trong chương 5. Chương 6 trình bày về cách kết hợp khoảng cách LT-MHD trong một mạng CNN để trích đặc trưng ảnh khuôn mặt. Các kết luận của luận án được trình bày trong chương 7.

CHƯƠNG 2 CƠ SỞ LÝ THUYẾT

Các phương pháp nhận dạng khuôn mặt trong điều kiện SSPP

Các phương pháp nhận dạng khuôn mặt dựa trên đặc trưng được trích từ toàn bộ bức ảnh (Global methods) sẽ biểu diễn đặc trưng của toàn bộ bức ảnh bằng một vector có số chiều lớn. Các phương pháp này có ưu điểm là giữ lại được toàn bộ thông tin của ảnh đầu vào, đơn giản để triển khai thực tế trong các hệ thống, tốn ít thời gian training và tốn ít dung lượng lưu trữ của hệ thống. Tuy nhiên các phương pháp này tồn tại một số nhược điểm. Đầu tiên, vector đặc trưng có số chiều lớn nên các thuật toán phân lớp sẽ có độ phức tạp tính toán cao và thời gian nhận dạng lớn. Một nhược điểm khác rất quan trọng của nhóm phương pháp này là việc tỷ lệ nhận dạng của các phương pháp trích đặc trưng toàn cục rất nhạy với sự thay đổi của bức ảnh. Tỷ lệ nhận dạng chính xác của các phương pháp trong nhóm này cũng chưa thật sự cao.

Các phương pháp nhận dạng khuôn mặt dựa trên đặc trưng cục bộ (Local methods) sử dụng các đặc trưng cục bộ để biểu diễn ảnh khuôn mặt. Các đặc trưng cục bộ này có thể được trích ra từ một phần của ảnh khuôn mặt hoặc được trích ra từ các điểm đặc trưng. Các phương pháp này có ưu điểm là tỷ lệ nhận dạng bền vững với nhiều điều kiện khác nhau của ảnh đầu vào, đơn giản hơn rất nhiều so với các phương pháp toàn cục trong việc triển khai trong các ứng dụng thực tế. Tuy nhiên, các phương pháp này vẫn tồn tại một số nhược điểm như việc đặc trưng của toàn bức ảnh không được trích xuất dẫn đến mất mát thông tin và độ phức tạp tính toán của các phương pháp này là tương đối cao.

Các phương pháp tạo ra các mẫu ảo để huấn luyện (Virtual sample generation based) sẽ sử dụng các phương pháp khác nhau để xây dựng thêm các ảnh từ một ảnh gốc của mỗi lớp. Việc tăng số lượng mẫu của mỗi lớp giúp các phương pháp nhận dạng trong điều kiện có nhiễu ảnh huấn luyện của một lớp có thể áp dụng để giải quyết bài toán SSPP. Tuy nhiên, nhược điểm của phương pháp này là đòi hỏi dung lượng lưu trữ lớn vì có rất nhiều ảnh được tạo thêm cũng như sự phức tạp tính toán cao, chất lượng và tính thực tế của các ảnh được tạo ra vẫn còn chưa đảm bảo. Một nhược điểm quan trọng nhất của nhóm các phương pháp này là việc các ảnh tạo ra có sự tương quan rất cao với các ảnh gốc.

Các phương pháp sử dụng thêm một tập dữ liệu chung để huấn luyện (Generic datasets based) sẽ sử dụng một tập dữ liệu chung để có thể học được các cách trích đặc trưng trên tập dữ liệu này và áp dụng vào để trích đặc trưng các ảnh trong tập mẫu và tập kiểm tra. Ưu điểm của các phương pháp này là các mô hình có thể học cách giải quyết các điều kiện không lý tưởng của ảnh đầu vào từ tập dữ liệu chung. Tuy nhiên nhược điểm lớn nhất của các phương pháp này là đòi hỏi dung lượng lưu trữ cực lớn cho các tập ảnh chung cũng như thời gian lớn cho việc huấn luyện, và việc tỷ lệ nhận dạng chính xác của các phương pháp này phụ thuộc trực tiếp vào tập ảnh chung được chọn.


Các phương pháp giảm độ phức tạp phép tính khoảng cách Hausdorff

Cho hai tập hợp A và B , khoảng cách Hausdorff trực tiếp giữa hai tập hợp được định nghĩa như sau:

$$h(A, B) = \max_{a \in A} \min_{b \in B} \|a - b\| \quad (2.2)$$

Khoảng cách Hausdorff trực tiếp là cực đại của khoảng cách từng điểm trong tập A đến điểm gần nhất tương ứng của nó trong tập B . Phép tính khoảng cách Hausdorff trực tiếp như công thức (2.2) sẽ có độ phức tạp là $O(PQ)$, trong đó P và Q lần lượt là tổng số phần tử trong hai tập hợp. Đã có rất nhiều các nghiên cứu được đề xuất nhằm giúp làm giảm độ phức tạp của phép tính khoảng cách Hausdorff, trong đó EARLYBREAK và LSS là hai phương pháp mới và nổi tiếng nhất.

Phương pháp EARLYBREAK đưa ra giải pháp giảm độ phức tạp của phép tính khoảng cách Hausdorff bằng cách bỏ qua các phép tính mà không làm ảnh hưởng đến kết quả của phép tính khoảng cách Hausdorff. Xét hai tập hợp M và T như hình 2.22, khoảng cách Hausdorff trực tiếp giữa hai tập hợp theo công thức (2.2) sẽ là $h(M, T) = \|m_1 - t_1\|$. Xét điểm m_1 , khoảng cách từ điểm này tới điểm gần nhất trong T là $\|m_1 - t_1\|$. Xét điểm m_2 , ta có khoảng cách $\|m_2 - t_1\| < \|m_1 - t_1\|$ nên khoảng cách từ điểm m_2 tới điểm gần nhất của nó trong T sẽ không đóng góp vào việc tính khoảng cách Hausdorff trực tiếp. Việc tính khoảng cách từ m_2 đến các điểm còn lại trong T có thể bỏ qua và tiếp tục với điểm m_3 .



Hình 2.22: Khoảng cách Hausdorff trực tiếp giữa hai tập hợp M và T

Phương pháp LSS cũng có giải pháp giảm độ phức tạp phép tính khoảng cách Hausdorff tương tự như phương pháp EARLYBREAK. Sự khác biệt của phương pháp LSS so với EARLYBREAK là các tập hợp được sắp xếp theo cấu trúc Morton. Đồng thời các vòng lặp trong trong phương pháp LSS sẽ bắt đầu tại vị trí xảy ra *break* ở vòng lặp ngoài trước đó.

Phương pháp LSS cũng có giải pháp giảm độ phức tạp phép tính khoảng cách

Hausdorff tương tự như phương pháp EARLYBREAK. Sự khác biệt của phương pháp LSS so với EARLYBREAK là các tập hợp được sắp xếp theo cấu trúc Morton. Đồng thời các vòng lặp trong trong phương pháp LSS sẽ bắt đầu tại vị trí xảy ra *break* ở vòng lặp ngoài trước đó.

CHƯƠNG 3 PHƯƠNG PHÁP LT-MMHD CHO NHẬN DẠNG KHUÔN MẶT

Khoảng cách mới được đề xuất - Least trimmed Modified Hausdorff distance (LT-MHD)

Khoảng cách Hausdorff, MAX-MIN Hausdorff, từ tập hợp M đến tập hợp T được tính là khoảng cách lớn nhất từ từng điểm m trong tập M đến điểm tương ứng của nó trong tập T . Nhược điểm của khoảng cách MAX-MIN này có nhược điểm là rất nhạy với nhiễu. Nếu có ít nhất một phần tử nhiễu trong một tập hợp, khoảng cách Hausdorff MAX-MIN sẽ chính là khoảng cách từ điểm nhiễu này đến điểm tương ứng của nó trong tập hợp còn lại. Các khoảng cách Hausdorff một phần

(Partial Hausdorff distance - PHD) và khoảng cách Hausdorff trung bình (Modified Hausdorff distance - MHD) đã được đề xuất để khắc phục tính nhạy với nhiễu của khoảng cách Hausdorff MAX-MIN. Trong nghiên cứu này, chúng tôi sẽ đề xuất một khoảng cách mới để đo sự giống nhau giữa hai tập hợp, khoảng cách Least trimmed Modified Hausdorff distance (LT-MHD). Khoảng cách LT-MHD là sự kết hợp của khoảng cách PHD và khoảng cách MHD. Khoảng cách LT-MHD trực tiếp từ một tập hợp M đến một tập hợp T được định nghĩa như sau:

$$h_{LT-MHD}(M, T) = \frac{1}{P-K} \sum_{i=K}^P \left(\min_{t \in T} \|m - t\| \right)_{(i)} \quad (3.4)$$

trong đó P là tổng số điểm của tập hợp M và $K = f \times P$ với f là một hệ số cho trước.

Phương pháp LT-MMHD cho nhận dạng khuôn mặt

Kết hợp giữa phương pháp MMHD và độ đo LT-MHD được đề xuất ở trên, chúng tôi đề xuất một phương pháp nhận dạng khuôn mặt trong điều kiện SSPP dựa trên đặc trưng cục bộ, phương pháp Least trimmed MMHD (LT-MMHD). Gọi $M = \{m_1, m_2, \dots, m_p\}$ và $T = \{t_1, t_2, \dots, t_o\}$ lần lượt là hai tập hợp các điểm trội của ảnh mẫu và ảnh cần nhận dạng. Khoảng cách LT-MHD được đề xuất ở trên sẽ được sử dụng để đo khoảng cách giữa hai tập hợp đặc trưng của ảnh khuôn mặt. Khoảng cách Hausdorff trực tiếp từ tập M đến tập T được định nghĩa như sau:

$$h_{LT-MMHD}(M, T) = \frac{1}{\sum_{m_i \in M} W_{m_i}} \sum_{i=K^{th}}^P W_{m_i} \left(\min_{t_j \in T} \|m_i - t_j\| \right)_i \quad (3.7)$$

trong đó P là tổng số điểm của tập hợp M và $K^{th} = f \times P$ với f là một hệ số cho trước. Giải thuật 12 trình bày cách tính khoảng cách Hausdorff trực tiếp từ tập M đến tập T trong phương pháp LT-MMHD. Ký hiệu $\langle \cdot, \cdot \rangle$ dùng để chỉ tích vô hướng của hai vector.

Giải thuật 12: Giải thuật tính khoảng cách Hausdorff trực tiếp phương pháp LT-MMHD

1. **Inputs:** Dominant point sets M and T , fraction f
 2. **Output:** Directed Hausdorff distance $h_{LT-MMHD}(M, T)$
 3. $K_M = (1-f) \times P$
 4. $h = \text{zeros}(2, K_M)$
 5. **for** each dominant point m in set point M **do**
 6. $[cmax, place] = \min(h(1,:))$
-

```

7.    $cmin = \infty$ 
8.   for each dominant point  $t$  in set point  $T$  do
9.      $dist = ||m - t||$ 
10.    if  $dist < cmin$  then
11.       $cmin = dist$ 
12.       $W = W_t$ 
13.    end if
14.  end for
15.  if  $cmax < cmin$  then
16.     $h(1, place) = cmin$ 
17.     $h(2, place) = 0.5 * (W_m + W)$ 
18.  end if
19. end for
20. return  $h_{LT-MMHD}(M,T) = \langle h(1,:), h(2,:) \rangle / sum(h(2,:))$ 

```

Một khoảng cách Hausdorff sơ cấp giữa hai tập hợp đặc trưng trong phương pháp LT-MMHD được định nghĩa như sau:

$$H_{p_{LT-MMHD}}(M, T) = \max(h_{LT-MMHD}(M, T), h_{LT-MMHD}(T, M)) \quad (3.8)$$

Bên cạnh đó, chúng tôi cũng đề xuất đưa thêm một chỉ số về độ tin cậy vào phép đo khoảng cách giữa hai tập hợp nhằm giúp làm tăng thêm tính chính xác. Khi tính khoảng cách Hausdorff trực tiếp từ tập M đến tập T , nếu một điểm trội m có điểm trung ứng của nó là t và khoảng cách của chúng nhỏ hơn một giá trị N_p thì điểm m này được gọi là một điểm tin cậy. Như vậy tỷ số độ tin cậy của một tập hợp là tỷ số giữa tổng số điểm tin cậy và tổng số điểm trong tập hợp đó. Một chỉ số không tin cậy khi tính khoảng cách giữa hai tập hợp được định nghĩa như sau:

$$D_n = 1 - \frac{R_M + R_T}{2} \quad (3.10)$$

trong đó R_M và R_T lần lượt là tỷ số độ tin cậy của tập M và tập T . Như vậy, khoảng cách Hausdorff giữa hai tập hợp trong phương pháp LT-MMHD được định nghĩa như sau:

$$H_{LT-MMHD}(M, T) = \sqrt{H_{p_{LT-MMHD}}^2(M, T) + W_n^2 D_n^2} \quad (3.11)$$

Áp dụng phương pháp Local Start Search (LSS) để giảm độ phức tạp cho phương pháp LT-MMHD

Trong giải thuật 12 có hai vòng lặp, vòng lặp ngoài (từ dòng 5 đến dòng 19) được thực hiện với tất cả các điểm $m \in M$ và vòng lặp trong (từ dòng 8 đến dòng 14)

được thực hiện với tất cả các điểm $t \in T$. Xét một điểm m ở vòng lặp ngoài, nếu tồn tại một điểm t ở vòng lặp trong mà làm cho giá trị $dist < cmax$ thì điểm m này được gọi là một điểm không đóng góp cho việc thay đổi giá trị của khoảng cách Hausdorff. Vì khoảng cách từ điểm m đến điểm tương ứng của nó sẽ là $cmin < dist$, và giá trị $cmin$ này sẽ không được cập nhật cho ma trận h theo điều kiện tại dòng 15. Như vậy với một điểm m như thế, việc tính khoảng cách tới tất cả các điểm $t \in T$ là không cần thiết và làm tăng độ phức tạp tính toán cho phương pháp LT-MMHD. Như vậy, nếu một điểm m ở vòng lặp ngoài tìm thấy một điểm t ở vòng lặp trong mà làm cho giá trị $dist < cmax$ thì thuật toán có thể **break** và tiếp tục với điểm m tiếp theo ở vòng lặp ngoài.

Phương pháp LSS là một phương pháp giúp tính nhanh khoảng cách Hausdorff bằng cách nhanh chóng xác định vị trí mà tại đó xảy ra break. Để làm được điều này, các tập hợp cần được sắp xếp lại theo một cấu trúc gọi là mã Morton. Hình 3.3 trình bày lưu đồ giải thuật để tính nhanh khoảng cách Hausdorff trực tiếp trong phương pháp LT-MMHD bằng cách áp dụng phương pháp LSS.

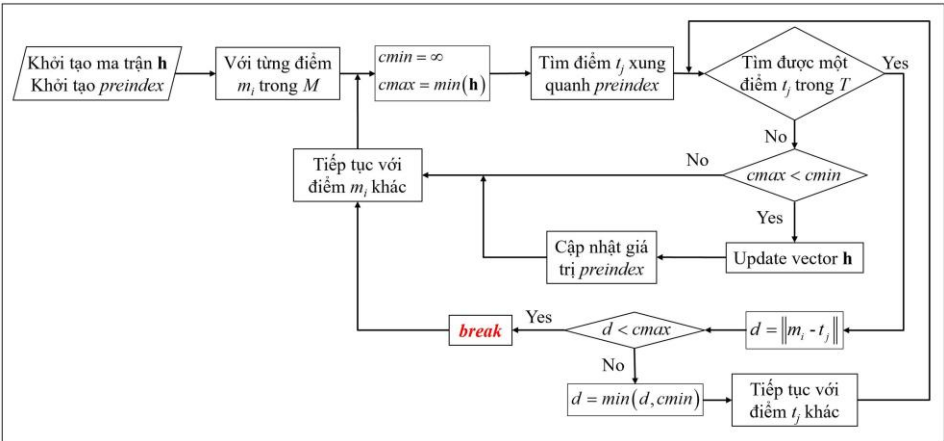
Tính toán độ phức tạp thuật toán của các phương pháp MMHD và phương pháp LT-MMHD

Gọi P và Q lần lượt là số điểm trội trong hai tập hợp M và T . Độ phức tạp của phép tính khoảng cách Hausdorff trực tiếp trong phương pháp MMHD sẽ là $O(PQ)$. Với việc áp dụng phương pháp LSS để tính nhanh khoảng cách Hausdorff trực tiếp trong phương pháp LT-MMHD, độ phức tạp của phép tính khoảng cách Hausdorff trực tiếp trong phương pháp LT-MMHD theo công thức (3.7) sẽ là $O((1-f)PQ + fP)$ trong trường hợp tốt nhất và là $O(PQ)$ trong trường hợp xấu nhất, trong đó f là một hệ số quyết định chất lượng của phương pháp và được chọn trước. Như vậy ta có thể thấy độ phức tạp tính toán của phương pháp LT-MMHD trong trường hợp xấu nhất sẽ chính là độ phức tạp tính toán của phương pháp MMHD. Điều này chứng tỏ phương pháp LT-MMHD có độ phức tạp tính toán thấp hơn so với phương pháp MMHD.

Trong trường hợp tổng quát, về trung bình, phép tính khoảng cách Hausdorff trực tiếp trong phương pháp LT-MMHD sẽ có độ phức tạp là $O((1-f)PQ + fPR)$, trong đó R là số vòng lặp trong trung bình khi thực hiện phép tính khoảng cách Hausdorff trực tiếp. Giả sử p là xác suất để khoảng cách d giữa một cặp điểm trội ở vòng lặp trong và vòng lặp ngoài nhỏ hơn giá trị $cmax$, $d < cmax$. Bằng lý thuyết về xác suất thống kê, ta có thể dễ dàng chứng minh được

$$E[R] = \frac{1}{p} \tag{3.17}$$

Như vậy ta thấy rằng kỳ vọng giá trị của R sẽ phụ thuộc vào xác suất p chứ không phụ thuộc vào độ lớn của hai tập hợp. Xác suất p sẽ phụ thuộc vào giá trị của $cmax$ và đồng thời giá trị của $cmax$ sẽ phụ thuộc vào giá trị của tỷ số f . Như vậy tỷ số f cũng sẽ là một giá trị quyết định độ phức tạp tính toán của phương pháp LT-MMHD.



Hình 3.3: Lưu đồ giải thuật tính nhanh khoảng cách Hausdorff trực tiếp trong phương pháp LT-MMHD

CHƯƠNG 4 PHƯƠNG PHÁP LT-LHD CHO NHẬN DẠNG KHUÔN MẶT

Phương pháp LHD cho nhận dạng khuôn mặt

Khác với phương pháp MMHD dùng tập hợp các điểm trội trong số các pixel cạnh làm đặc trưng của ảnh khuôn mặt, phương pháp LHD sử dụng tập hợp các đường cạnh nối giữa các điểm trội để làm đặc trưng của ảnh khuôn mặt, gọi là bản đồ cạnh. Gọi $M^l = \{m_1^l, m_2^l, \dots, m_p^l\}$ và $T^l = \{t_1^l, t_2^l, \dots, t_Q^l\}$ lần lượt tương ứng là bản đồ cạnh của ảnh mẫu và ảnh cần nhận dạng, ký hiệu * dùng để phân biệt với các điểm trội trong phương pháp MMHD. Phương pháp LHD sử dụng khoảng cách Hausdorff trung bình để đo khoảng cách giữa hai bản đồ cạnh này, trong đó khoảng cách Hausdorff trực tiếp là trung bình có trọng số của khoảng cách giữa các cặp đường cạnh tương ứng trong hai tập hợp. Khoảng cách giữa hai đường cạnh được định nghĩa như sau:

$$d(m^l, t^l) = \sqrt{d_\theta^2(m^l, t^l) + d_\parallel^2(m^l, t^l) + d_\perp^2(m^l, t^l)} \quad (4.5)$$

trong đó các ký hiệu $d_\theta(m^l, t^l)$ là khoảng cách góc giữa hai đường cạnh và dùng để đo sự sai lệch về hướng giữa hai đường cạnh; $d_\parallel(m^l, t^l)$, $d_\perp(m^l, t^l)$ lần lượt là khoảng cách song song, khoảng cách vuông góc và được dùng để đo sự lệch nhau về không gian giữa hai đường. Một khoảng cách Hausdorff sơ cấp trong phương pháp LHD được định nghĩa như sau:

$$H_{pLHD}(M^l, T^l) = \max(h_{LHD}(M^l, T^l), h_{LHD}(T^l, M^l)) \quad (4.6)$$

trong đó $h_{LHD}(M^l, T^l)$ là khoảng cách Hausdorff trực tiếp và được định nghĩa:


$$h_{LHD}(M^l, T^l) = \frac{1}{\sum_{m^l \in M^l} l_{m^l}} \sum_{m^l \in M^l} l_{m^l} \cdot \min_{t^l \in T^l} d(m^l, t^l) \quad (4.7)$$

với l_{m^l} là chiều dài của đường cạnh m^l . Một chỉ số về độ tin cậy cũng được thêm vào phép tính khoảng cách Hausdorff giữa hai bản đồ cạnh. Nếu một đường cạnh m^l trong bản đồ cạnh này có đường cạnh tương ứng trong là t^l trong bản đồ cạnh kia và sự sai lệch về hướng giữa chúng nhỏ hơn một khoảng N_a và sự sai lệch về không gian nhỏ hơn một khoảng N_p thì đường cạnh m^l được gọi là một đường cạnh có độ tin cậy cao. Tỷ số độ tin cậy của một bản đồ cạnh là tỷ số giữa tổng số đường cạnh có độ tin cậy cao và tổng số đường cạnh trong bản đồ cạnh đó. Một chỉ số đo về độ không tin cậy giữa hai bản đồ cạnh cũng được định nghĩa như tại phương trình (3.10). Như vậy khoảng cách Hausdorff giữa hai tập hợp trong phương pháp LHD được định nghĩa như sau:

$$H_{LHD}(M^l, T^l) = \sqrt{H_{pLHD}^2(M^l, T^l) + (W_n D_n)^2} \quad (4.11)$$

Cải tiến tiến phương pháp LHD, phương pháp RLHD

Các đường cạnh phản ánh cấu trúc của khuôn mặt. Nếu hai bản đồ cạnh là đặc trưng của hai ảnh khuôn mặt của cùng một người thì các đường cạnh tương ứng trong hai bản đồ cạnh sẽ có sự tương đồng về hướng. Để tăng tính chính xác trong việc tìm kiếm các cặp đường cạnh tương ứng trong hai bản đồ cạnh, chúng tôi sẽ dựa vào sự tương đồng về hướng để tìm kiếm các cặp đường cạnh tương ứng trong hai bản đồ cạnh. Trước tiên, chúng tôi đề xuất một cấu trúc mới cho bản đồ cạnh, trong đó các đường cạnh sẽ được sắp xếp vào các nhóm dựa vào góc tạo bởi các đường cạnh và phương ngang. Do góc của các đường cạnh thay đổi từ 0°



đến 180° nên chúng tôi sẽ tạo ra 18 nhóm cho một bản đồ cạnh. Hình 4.5 mô tả cấu trúc mới của bản đồ cạnh.

Dựa trên cấu trúc mới này của bản đồ cạnh, chúng tôi đề xuất một khoảng cách mới giữa hai đường cạnh như sau:

Hình 4.5: Cấu trúc dữ liệu mới cho bản đồ cạnh

$$d_{RLHD}(m^l, t^l) = \begin{cases} \|m^l, t^l\| & \text{ne } g_{m^l} - k \leq g_{t^l} \leq g_{m^l} + k \\ V & \text{trung hợp khác} \end{cases} \quad (4.16)$$

trong đó $\|m^l, t^l\|$ là khoảng cách giữa hai đường cạnh được tính như tại công thức (4.5). Việc tính khoảng cách Hausdorff giữa hai bản đồ cạnh cũng được tính giống như phương pháp LHD ở trên.

Phương pháp LT-LHD cho nhận dạng khuôn mặt

Kết hợp giữa khoảng cách LT-MHD được đề xuất trong chương 3 cùng phương pháp RLHD, chúng tôi đề xuất phương pháp LT-LHD cho nhận dạng khuôn mặt. Phương pháp LT-LHD vẫn sử dụng cấu trúc bản đồ cạnh như phương pháp RLHD cũng như cách tính khoảng cách giữa hai đường cạnh như phương trình

(4.16). Tuy nhiên, phương pháp LT-LHD sử dụng khoảng cách được đề xuất LT-MHD để đo khoảng cách giữa hai bản đồ cạnh thay vì sử dụng khoảng cách Hausdorff trung bình như phương pháp RLHD. Khoảng cách Hausdorff trực tiếp từ bản đồ cạnh M đến bản đồ cạnh T được định nghĩa như sau:

$$h_{LT-LHD} = \frac{1}{\sum_{i=K^{th}}^{N_M} l_{m_i}} \sum_{i=K^{th}}^P \left(l_{m_i} \cdot \min_{t^l \in T^l} d(m^l, t^l) \right)_i \quad (4.20)$$

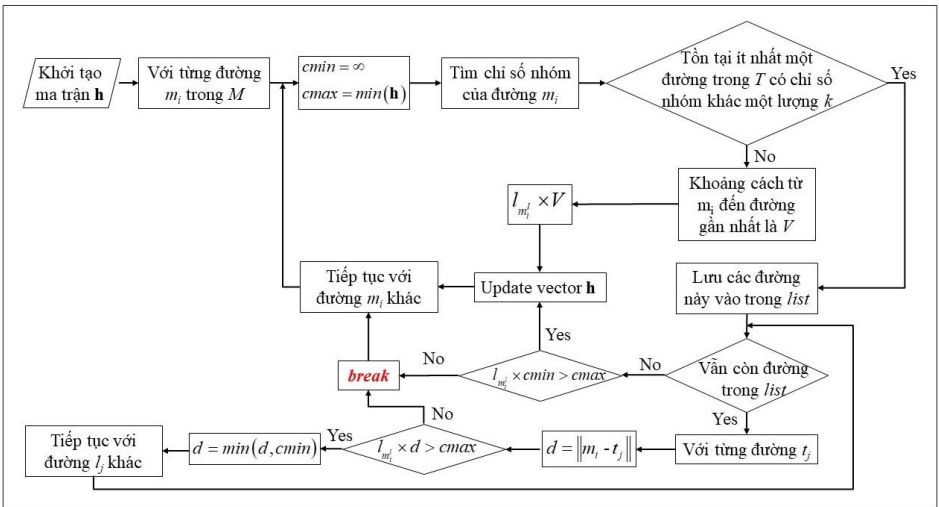
Giải thuật 14 trình bày cách tính khoảng cách Hausdorff trực tiếp trong phương pháp LT-LHD. Khoảng cách Hausdorff giữa hai bản đồ cạnh trong phương pháp LT-LHD cũng được tính tương tự như phương pháp LHD. Bên cạnh đó, chỉ số về độ tin cậy cũng được thêm vào để giúp làm tăng thêm tính chính xác cho việc nhận dạng.

Giải thuật 14: Giải thuật tính khoảng cách Hausdorff trực tiếp phương pháp LT-LHD từ M^l đến T^l

-
1. **Inputs:** Edge map M^l and edge map T^l , fraction f
 2. **Output:** Directed Hausdorff distance $h_{LT-MMHD}(M, T)$
 3. $K_M = (1-f) \times P$
 4. $h = \text{zeros}(2, K_M)$
 5. **for** each line segment m^l in edge map M^l **do**
 6. Get the group index g_m of line segment m^l
 7. $cmin = \infty$
 8. $cmax = \min(h(1, :))$
 9. **for** $g_t = g_m - k : g_m + k$ **do**
 10. Insert the line segment t^l has group index g_t into *list*
 11. **end for**
 12. **if** *list* is not empty **then**
 13. **for** each line segment t^l in *list* **do**
 14. $d = \text{DIST}(m^l, t^l)$
 15. $cmin = \min(cmin, d)$
 16. **end for**
 17. **if** $cmin * l_m > cmax$ **then**
 18. $h(1, 1) = cmin * l_m$
 19. $h(2, 1) = l_m$
 20. **end if**
 21. **else**
 22. $h(1, 1) = V * l_m$
 23. $h(2, 1) = l_m$
 24. **end if**
 25. Sort h in ascending order of the value of the first row
 26. **end for**
 27. **return** $h_{LT-LHD}(M^l, T^l) = \text{sum}(h(1, :)) / \text{sum}(h(2, :))$
-

Áp dụng phương pháp EARLYBREAK để làm giảm độ phức tạp tính toán cho phương pháp LT-LHD

Trong giải thuật 14, vòng lặp trong (từ dòng 13 đến dòng 16) không nhất thiết phải thực được thực hiện với toàn bộ các đường cạnh trong *list*. Gọi *cmax* là giá trị nhỏ nhất trong số các giá trị của $l_{m_i} \cdot \min_{t^l \in T^l} d(m^l, t^l)$. Giả sử đường cạnh m^l ở vòng lặp ngoài tìm thấy một đường cạnh t^l ở vòng lặp trong mà khoảng cách *d* giữa chúng làm cho $l_{m_i} \cdot d < cmax$ thì đường cạnh m^l đó được gọi là một đường không đóng góp vào việc tính khoảng cách Hausdorff giữa hai bản đồ cạnh. Vì vậy việc tính khoảng cách từ đường m^l đến những đường cạnh còn lại ở vòng lặp trong là không cần thiết vì sẽ không làm thay đổi giá trị của khoảng cách Hausdorff giữa hai bản đồ cạnh. Vì vậy khi xảy ra trường hợp này, thuật toán có thể break các vòng lặp trong và tiếp tục với vòng lặp ngoài tiếp theo. Điều này sẽ làm giảm đáng kể độ phức tạp tính toán của phương pháp LT-LHD. Phương pháp EARLYBREAK sẽ được áp dụng để xác định vị trí vòng lặp trong là thuật toán có thể **break**. Hình 5.6 trình bày giải thuật để tính nhanh khoảng cách Hausdorff



Hình 4.6: Lưu đồ giải thuật tính nhanh khoảng cách Hausdorff trực tiếp trong phương pháp LT-LHD

trực tiếp trong phương pháp LT-LHD bằng cách áp dụng phương pháp EARLYBREAK.

Tính toán độ phức tạp thuật toán của các phương pháp LHD và phương pháp LT-LHD

Gọi P và Q lần lượt là số đường cạnh trong hai bản đồ cạnh M^l và T^l . Độ phức tạp của phép tính khoảng cách Hausdorff trực tiếp trong phương pháp LHD theo công thức (4.7) sẽ là $O(PQ)$. Khi chưa áp dụng phương pháp LSS, phép tính khoảng cách trực tiếp trong phương pháp LT-LHD như công thức (4.20) cũng có độ phức tạp là $O(PQ)$. Khi áp dụng phương pháp LSS để tính nhanh phép tính khoảng cách trực tiếp, phương pháp LT-LHD có độ phức tạp phép tính khoảng cách Hausdorff trực tiếp giữa hai bản đồ cạnh lần lượt là $O(P)$ và $O(PQ)$ trong trường hợp tốt nhất và xấu nhất. Trong trường hợp tốt nhất, với mỗi đường cạnh m^l , thuật toán sẽ **break** ngay tại đường cạnh t^l đầu tiên theo giải thuật ở hình 4.6. Trong trường hợp xấu nhất, thuật toán sẽ không bao giờ xảy ra **break**. Trong trường hợp tổng quát, phép tính khoảng cách Hausdorff trực tiếp trong phương pháp LT-LHD sẽ có độ phức tạp là $O((1-f)PQ(2k+1)/18+fPR)$, trong đó R là số vòng lặp trong trung bình. Tương tự như phương pháp LT-MMHD, bằng lý thuyết về xác suất thống kê, kỳ vọng của R sẽ được tính như công thức (3.17).

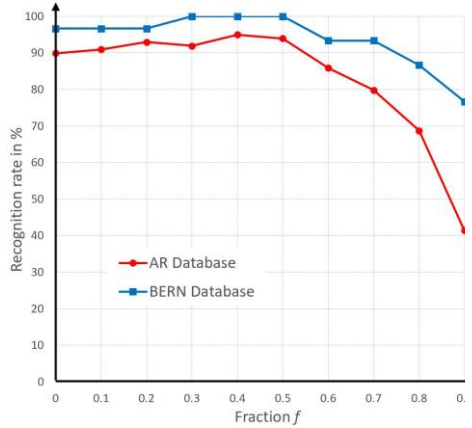
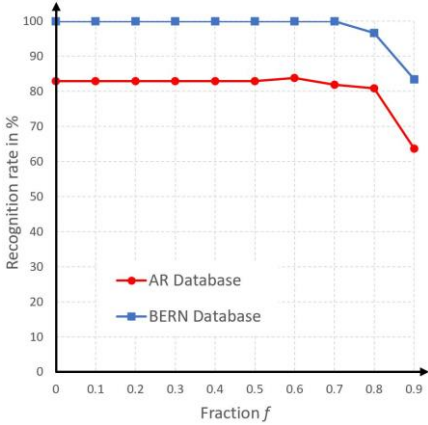
CHƯƠNG 5 KẾT QUẢ MÔ PHỎNG

Mô tả cơ sở dữ liệu

Trong nghiên cứu này, 3 bộ cơ sở dữ liệu khuôn mặt chuẩn: Bern University face database, AR face database và ORL face database sẽ được sử dụng để kiểm tra khả năng nhận dạng của các phương pháp được đề xuất trong nghiên cứu này. Hai tập dữ liệu khuôn mặt AR và Bern University được sử dụng để kiểm tra khả năng nhận dạng khuôn mặt của các phương pháp với nhiều điều kiện khác nhau của ảnh đầu vào. Tập dữ liệu ORL được sử dụng để so sánh khả năng nhận dạng của các phương pháp đề xuất với các phương pháp trong các nghiên cứu khác. Tập dữ liệu ORL là tập dữ liệu thường được các nghiên cứu sử dụng khi cần so

sánh khả năng nhận dạng giữa các phương pháp khác nhau vì có cùng một cách thức thí nghiệm.

Khảo sát ảnh hưởng của hệ số f lên chất lượng của phương pháp LT-LHD và LT-MMHD



Hình 5.6: Ảnh hưởng của f đến tỷ lệ nhận dạng của phương pháp LT-MMHD

Hình 5.7: Ảnh hưởng của f đến tỷ lệ nhận dạng của phương pháp LT-LHD

Trong các phương pháp LT-MMHD và phương pháp LT-LHD, tỷ số f sẽ phản ánh số lượng đường cạnh hoặc số lượng các điểm trội được sử dụng để tính khoảng cách Hausdorff trực tiếp trong các phương pháp. Giá trị của f sẽ thay đổi trong khoảng $0 \div 0.9$. Giá trị $f = 1$ là vô nghĩa vì khi đó sẽ không có đường cạnh/điểm trội nào được sử dụng để tính khoảng cách Hausdorff. Không có lý thuyết để chọn giá trị f để tỷ lệ nhận dạng của hai phương pháp LT-MMHD và phương pháp LT-LHD đạt tối ưu. Vì vậy trong nghiên cứu này lựa chọn tỷ số f dựa vào thực nghiệm, tối ưu tỷ lệ nhận dạng của hai phương pháp LT-MMHD và phương pháp LT-LHD trong điều kiện bình thường của ảnh khuôn mặt. Hai tập dữ liệu AR và Bern sẽ được sử dụng trong mô phỏng này. Hình 5.6 và hình 5.7 mô tả sự ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của các phương pháp LT-LHD và phương pháp LT-MMHD. Tỷ lệ nhận dạng của phương pháp LT-MMHD đạt cực đại tại $f = 0.6$ nên giá trị này được chọn cho các mô phỏng ở phần sau. Tương tự, giá trị $f = 0.4$ được chọn cho phương pháp LT-LHD ở các

mô phỏng sau. Vị trí $f=0$ tương ứng với việc khoảng cách Hausdorff trung bình được sử dụng để tính khoảng cách giữa hai tập hợp thay vì khoảng cách LT-MHD. Các kết quả đều cho thấy sự cải thiện về tỷ lệ nhận dạng của các phương pháp nhận dạng khuôn mặt khi sử dụng khoảng cách LT-MHD thay vì khoảng cách Hausdorff trung bình để đo khoảng cách giữa hai tập đặc trưng.

Chứng minh giảm độ phức tạp tính toán của các phương pháp LT-MMHD và phương pháp LT-LHD

Trong nghiên cứu này, số vòng lặp trong trung bình và thời gian khi thực hiện phép tính khoảng cách giữa hai ảnh được dùng so sánh và đánh giá sự hiệu quả trong việc giảm độ phức tạp tính toán. Bảng 5.1 trình bày kết quả so sánh giữa phương pháp MMHD và phương pháp LT-MMHD. Phương pháp LT-MMHD có số vòng lặp trong trung bình, hay độ phức tạp tính toán, thấp hơn 17% và thời gian tính toán thấp hơn 15% so với phương pháp MMHD. Tương tự, các kết quả trong bảng 5.2, phương pháp LT-LHD có độ phức tạp tính toán thấp hơn 67% và thời gian tính toán thấp hơn 63-65% so với phương pháp LHD. Các kết quả này đều cho thấy sự hiệu quả khi áp dụng các phương pháp như EARLYBREAK và LSS để làm giảm độ phức tạp cho các phương pháp nhận dạng khuôn mặt.

Bảng 5.1: Số vòng lặp trong trung bình và thời gian tính khoảng cách giữa hai ảnh của phương pháp MMHD và LT-MMHD

Method	Bern database		AR database	
	MMHD	LT-MMHD	MMHD	LT-MMHD
Average inner loop (x 10 ³)	1204	1003	792.9	660.8
Decrease (%)	-	16.67	-	16.66
Matching time (ms)	8.3	6.9	5.1	4.3
Decrease (%)	-	16.86	-	15.7

Bảng 5.2: Số vòng lặp trong trung bình và thời gian tính khoảng cách giữa hai ảnh của phương pháp LHD và LT-LHD

Method	Bern database		AR database	
	LHD	LT-LHD	LHD	LT-LHD
Average inner loop (x 10 ³)	62.76	20.83	40.77	13.59
Decrease (%)	-	66.81	-	66.67
Matching time (ms)	147	55	99	35
Decrease (%)	-	62.58	-	64.6

Nhận dạng khuôn mặt trong điều kiện bình thường

Trong mô phỏng này, các cặp ảnh khuôn mặt chính diện trong điều kiện bình thường trong tập dữ liệu AR và Bern sẽ được sử dụng. Bảng 5.3 trình bày kết quả so sánh tỷ lệ nhận dạng khuôn mặt của phương pháp đề xuất LT-MMHD và phương pháp MMHD trong điều kiện bình thường. Các kết quả cho thấy phương pháp LT-MMHD cho kết quả nhận dạng cao hơn khoảng 6-9% so với phương pháp MMHD. Tương tự, các kết quả ở bảng 5.4 cũng cho thấy phương pháp LT-LHD cho tỷ lệ nhận dạng cao hơn phương pháp LHD khoảng 2%. Các kết quả này cho thấy việc sử dụng khoảng cách LT-MHD để đo khoảng cách giữa các tập đặc trưng sẽ giúp làm tăng tỷ lệ nhận dạng của các phương pháp nhận dạng khuôn mặt so với việc sử dụng khoảng cách Hausdorff trung bình.

Bảng 5.3: Tỷ lệ nhận dạng khuôn mặt của phương pháp MMHD và LT-MMHD trong điều kiện bình thường

Method	Recognition rate	
	Bern database	AR database
MMHD	93.93%	74.75%
LT-MMHD	100%	83.84%

Bảng 5.4: Tỷ lệ nhận dạng khuôn mặt của phương pháp LHD và LT-LHD trong điều kiện bình thường

Method	Recognition rate	
	Bern database	AR database
LHD	100%	92.92%
LT-LHD	100%	94.94%

Nhận dạng khuôn mặt trong các điều kiện ánh sáng khác nhau

Bảng 5.5 và 5.6 lần lượt trình bày các kết quả so sánh về tỷ lệ nhận dạng khuôn mặt giữa các phương pháp MMHD và phương pháp LT-MMHD, phương pháp LHD và phương pháp LT-LHD trong các điều kiện ánh sáng khác nhau của ảnh đầu vào như: khuôn mặt bị chiếu sáng bên trái, bên phải và từ hai bên. Về trung bình, phương pháp LT-MMHD cho kết quả cao hơn 19% so với phương pháp MMHD và phương pháp LT-LHD cho kết quả nhận dạng cao hơn 2% so với phương pháp LHD. Các kết quả này cho thấy với các điều kiện khác nhau về ánh

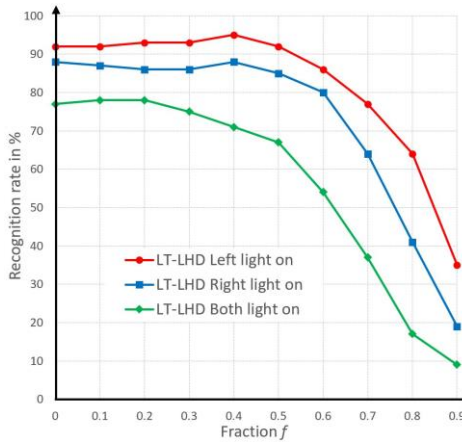
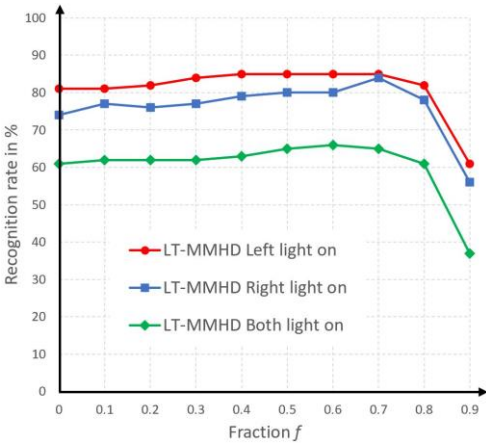
sáng của ảnh đầu vào, việc sử dụng khoảng cách LT-MHD thay vì khoảng cách Hausddorff trung bình để đo khoảng cách giữa các tập hợp đặc trưng vẫn mang lại sự cải thiện về tỷ lệ nhận dạng.

Bảng 5.5: Tỷ lệ nhận dạng khuôn mặt của phương pháp MMHD và LT-MMHD trong điều kiện ánh sáng khác nhau

Lighting condition	Recognition rate	
	MMHD	LT-MMHD
Left light on	71%	85%
Right light on	64%	80%
Both light on	49%	76%
Average	61.33%	80.33%

Bảng 5.6: Tỷ lệ nhận dạng khuôn mặt của phương pháp LHD và LT-LHD trong điều kiện ánh sáng khác nhau

Lighting condition	Recognition rate	
	LHD	LT-LHD
Left light on	92%	95%
Right light on	86%	88%
Both light on	70%	71%
Average	82.67%	84.67%



Hình 5.10: Ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-MMHD trong các điều kiện chiếu sáng khác nhau

Hình 5.13: Ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-LHD trong các điều kiện chiếu sáng khác nhau

Hình 5.10 và 5.13 lần lượt mô tả về sự ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-MMHD và phương pháp LT-LHD với các điều kiện ánh sáng khác nhau của ảnh đầu vào. Các kết quả cho thấy rằng trong tất cả các điều kiện ánh sáng khác nhau, phương pháp LT-LHD và phương pháp LT-MMHD đều đạt tỷ lệ nhận dạng cực đại tại các vị trí $f > 0$. Điều này cho thấy rằng việc thay đổi từ sử dụng khoảng cách Hausdorff trung bình sang khoảng cách LT-MMHD sẽ mang lại sự cải thiện về tỷ lệ nhận dạng cho các phương pháp.

Nhận dạng khuôn mặt với các góc chụp khác nhau

Kết quả so sánh về tỷ lệ nhận dạng giữa phương pháp LT-MMHD và phương pháp MMHD trong bảng 5.7 cho thấy phương pháp LT-MMHD cho tỷ lệ nhận dạng cao hơn 10% về mặt trung bình so với phương pháp MMHD khi ảnh đầu vào được chụp ở các góc khác nhau. Tương tự, kết quả ở bảng 5.8 cũng cho thấy phương pháp LT-LHD cho tỷ lệ nhận dạng cao hơn phương pháp LHD khoảng 5% về mặt trung bình ở các điều kiện góc chụp khác nhau. Hình 5.14 và 5.16 lần lượt mô tả về sự ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-

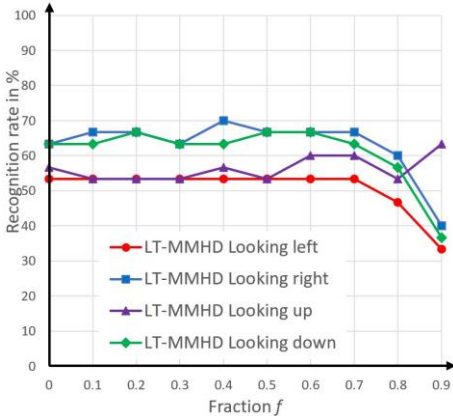
Bảng 5.7: Tỷ lệ nhận dạng khuôn mặt của phương pháp MMHD và phương pháp LT-MMHD với các góc chụp khác nhau của khuôn mặt

Test face	Methods	
	MMHD	LT-MMHD
Looks left	40%	53.33%
Looks right	53.33%	66.67%
Looks up	60%	60%
Looks down	53.33%	66.67%
Average	51.67%	61.67%

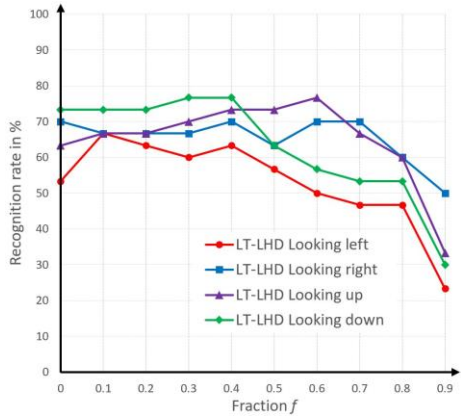
Bảng 5.8: Tỷ lệ nhận dạng khuôn mặt của phương pháp LHD và phương pháp LT-LHD với các góc chụp khác nhau của khuôn mặt

Test face	Methods	
	LHD	LT-LHD
Looks left	56.67%	63.33%
Looks right	60%	70%
Looks up	76.67%	73.33%
Looks down	70%	76.67%
Average	65.83%	70.83%

MMHD và phương pháp LT-MMHD khi ảnh chụp khuôn mặt với các góc chụp khác nhau. Trong tất cả các điều kiện khác nhau về góc chụp khuôn mặt, phương pháp LT-LHD và LT-MMHD đều đạt tỷ lệ nhận dạng cực đại tại các vị trí $f > 0$. Điều này chứng tỏ việc sử dụng khoảng cách LT-MMHD sẽ mang lại sự hiệu quả hơn khoảng cách Hausdorff trung bình trong điều kiện nhận dạng khuôn mặt ở các góc chụp khác nhau.



Hình 5.14: Ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-MMHD trong các điều kiện góc nhìn khác nhau của khuôn mặt.



Hình 5.16: Ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-LHD trong các điều kiện góc nhìn khác nhau của khuôn mặt.

Nhận dạng khuôn mặt với các cảm xúc khác nhau của khuôn mặt

Kết quả so sánh ở bảng 5.9 cho thấy khi ảnh chụp khuôn mặt với các cảm xúc khác nhau, phương pháp LT-MMHD cho tỷ lệ nhận dạng cao hơn phương pháp MMHD khoảng 17% về trung bình. Tương tự, các kết quả ở bảng 5.10 cho thấy

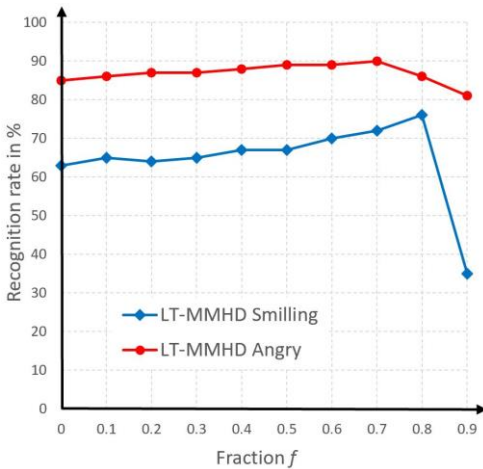
Bảng 5.9: Tỷ lệ nhận dạng khuôn mặt của phương pháp MMHD và phương pháp LT-MMHD với các cảm xúc khác nhau của khuôn mặt

Test face	Methods	
	MMHD	LT-MMHD
Smiling	40%	70%
Angry	85%	89%
Average	62.5%	79.5%

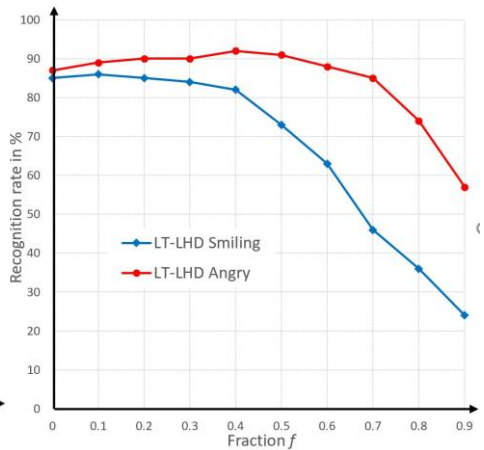
Bảng 5.10: Tỷ lệ nhận dạng khuôn mặt của phương pháp LHD và phương pháp LT-LHD với các cảm xúc khác nhau của khuôn mặt

Test face	Methods	
	LHD	LT-LHD
Smiling	79%	82%
Angry	90%	92%
Average	84.5%	87%

phương pháp LT-LHD cho kết quả nhận dạng cao hơn phương pháp LHD khoảng 2.5% về trung bình. Hình 5.19 và 5.23 lần lượt mô tả về sự ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng khuôn mặt của phương pháp LT-MMHD và phương pháp LT-LHD khi ảnh chụp khuôn mặt với các cảm xúc khác nhau. Các kết quả cho thấy phương pháp LT-LHD và phương pháp LT-MMHD đều đạt tỷ lệ nhận dạng cực đại tại các vị trí $f > 0$. Điều này cho thấy việc thay đổi từ sử dụng khoảng cách Hausdorff trung bình sang khoảng cách LT-MHD sẽ mang lại sự cải thiện về tỷ lệ nhận dạng cho các phương pháp nhận dạng khuôn mặt.



Hình 5.19: Ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-MMHD trong các điều kiện cảm xúc khác nhau của khuôn mặt.



Hình 5.23: Ảnh hưởng của tỷ số f đến tỷ lệ nhận dạng của phương pháp LT-LHD trong các điều kiện cảm xúc khác nhau của khuôn mặt.

So sánh tỷ lệ nhận dạng của các phương pháp đề xuất với các phương pháp nhận dạng khuôn mặt khác trong điều kiện SSPP

Trong mô phỏng này, tập dữ liệu khuôn mặt ORL được sử dụng để so sánh tỷ lệ nhận dạng của các phương pháp đề xuất với các phương pháp nhận dạng khuôn mặt khác trong điều kiện SSPP. Cách mô phỏng được thực hiện hoàn toàn giống như các phương pháp so sánh: một ảnh của mỗi người trong tập dữ liệu ORL được sử dụng làm tập dữ liệu và các ảnh còn lại được sử dụng để làm tập kiểm tra. Các kết quả so sánh trong bảng 5.11 cho thấy hai phương pháp LT-MMHD và phương pháp LT-LHD cho kết quả khá tốt. Đặc biệt, phương pháp LT-LHD có tỷ lệ nhận dạng cao hơn 2-11% so với các phương pháp được so sánh.

Bảng 5.11: So sánh tỷ lệ nhận dạng của các phương pháp đề xuất với các phương pháp khác trong điều kiện bài toán SSPP với tập dữ liệu ORL

	Year	Method	Accuracy
Global feature-based methods	2019	[43]	71.94%
	2020	[38]	76.61%
	2020	[41]	73.89%
Local feature-based methods	2019	[50]	76%
	2020	[56]	69.87%
	2020	[55]	79.72%
Virtual sample generation-based methods	2018	[69]	77.44%
	2019	[66]	75%
	2019	[70]	75%
Generic dataset-based method	2008	[71]	72.4
Proposed methods	2021	LT-MMHD [87]	71.4%
	2020	LT-LHD [90]	81.11%

Kết luận chương 5

Trong chương này, chúng tôi đã trình bày các kết quả mô phỏng về tỷ lệ nhận dạng của các phương pháp LT-MMHD và phương pháp LT-LHD. Các kết quả mô phỏng cho thấy rằng hai phương pháp LT-LHD và phương pháp LT-MMHD cho kết quả nhận dạng tốt hơn hai phương pháp LHD và phương pháp MMHD trong tất cả các mô phỏng. Điều này cho thấy việc sử dụng khoảng cách LT-

MHD thay cho khoảng cách Hausdorff trung bình sẽ mang đến sự cải thiện tỷ lệ nhận dạng cho các phương pháp. Tùy theo điều kiện khác nhau của ảnh đầu vào, việc sử dụng khoảng cách LT-MHD mang lại sự cải thiện 2-10% tỷ lệ nhận dạng. Ngoài ra, việc sử dụng khoảng cách LT-MHD với các loại đặc trưng khác nhau cũng cho thấy khoảng cách LT-MHD có thể được sử dụng hiệu quả với nhiều loại đặc trưng khác nhau của ảnh khuôn mặt. Bên cạnh đó, khi so sánh với các phương pháp nhận dạng khuôn mặt khác trong những năm gần đây, hai phương pháp đề xuất cho kết quả khá tốt. Đặc biệt là phương pháp LT-LHD cho kết quả cao hơn 2-11% so với các phương pháp được so sánh khác.

CHƯƠNG 6 KẾT HỢP PHÉP ĐO LT-MHD VỚI CÁC MÔ HÌNH HỌC SÂU

Các phương pháp nhận dạng khuôn mặt trong điều kiện SSPP dựa trên học sâu

Bên cạnh các phương pháp nhận dạng khuôn mặt trong điều kiện SSPP truyền thống được đề cập tại chương 2, trong những năm gần đây, cũng có rất nhiều các phương pháp nhận dạng khuôn mặt dựa trong điều kiện SSPP dựa trên học sâu được đề xuất. Ưu điểm của các phương pháp này là các mô hình có thể học được các đặc trưng bền vững của ảnh khuôn mặt từ một tập dữ liệu rất lớn, có tỷ lệ nhận dạng chính xác khá cao và bền vững với các điều kiện khác nhau của ảnh đầu vào. Tuy nhiên, các phương pháp này cũng có một số các nhược điểm như thời gian huấn luyện rất lớn và rất khó mở rộng hệ thống.

Các phương pháp nhận dạng khuôn mặt trong điều kiện SSPP dựa trên học sâu có thể được chia thành hai hướng chính: các phương pháp tạo thêm các mẫu ảo để huấn luyện và các phương pháp sử dụng thêm một tập chung để huấn luyện. Các phương pháp tạo thêm mẫu ảo sẽ sử dụng các mô hình như Auto Encoder (AE) hoặc Generative Adversarial Networks (GAN) để tạo thêm các ảnh ảo hoặc đặc trưng ảo, giúp làm tăng số lượng mẫu của tập huấn luyện. Các phương pháp sử dụng thêm tập dữ liệu chung sẽ sử dụng tập mẫu kết hợp với một tập dữ liệu chung lớn để làm tập huấn luyện cho các mô hình học sâu. Các mô hình học sâu

sẽ học cách trích các đặc trưng trên tập dữ liệu chung, sau đó áp dụng vào tập mẫu.

Kết hợp độ đo LT-MHD cùng mô hình học sâu để trích đặc trưng ảnh khuôn mặt

Việc nghiên cứu về một phương pháp nhận dạng khuôn mặt trong điều kiện SSPP dựa trên học sâu không phải là mục tiêu ban đầu của nghiên cứu này. Tuy nhiên vì đây là hướng nghiên cứu mới và đang rất phát triển nên chúng tôi cũng hướng đến việc áp dụng một số kết quả có được từ nghiên cứu này vào trong hướng phát triển này. Trong nghiên cứu này không hướng đến việc đề xuất một phương pháp nhận dạng khuôn mặt trong điều kiện SSPP mà chỉ đề xuất một mô hình trích đặc trưng ảnh khuôn mặt dựa trên học sâu trong điều kiện SSPP.

Trong nghiên cứu này, chúng tôi sẽ sử dụng lại một mô hình mạng đã được huấn luyện trước, mạng InceptionV3. Tuy nhiên mạng này được huấn luyện với tập dữ liệu ImageNet để có ngõ ra 1000 lớp phân biệt các ảnh về chuột, bàn phím, động vật... nên chúng tôi phải tiến hành điều chỉnh một số lớp của mạng này và tiến hành huấn luyện lại mạng với các tập dữ liệu ảnh khuôn mặt của chúng tôi. Đầu tiên, chúng tôi sẽ thay đổi lớp Fully connected (Lớp kết nối đầy đủ) để ngõ ra có số lớp phù hợp với tập dữ liệu. Tiếp theo, chúng tôi sẽ định nghĩa mới một lớp phân lớp đầu ra, trong đó khoảng cách LT-MHD được sử dụng như hàm mất mát giữa ngõ ra dự đoán và ngõ ra mong muốn thay vì hàm cross-entropy như nguyên mẫu của mạng. Gọi Y và T lần lượt ngõ ra dự đoán của mạng và ngõ ra mong muốn của quá trình huấn luyện. Hàm mất mát L của mạng được định nghĩa như sau:

$$L = \frac{1}{P - K} \sum_{i=1}^K \left(\min_{t_j \in T} \|y_i - t_j\| \right)_{(i)} \quad \text{where } j = 1 \div C \quad (6.1)$$

trong đó P là tổng số mẫu đưa vào huấn luyện, C là tổng số với huấn luyện, y_i là vector đầu ra của mạng tương ứng một ảnh đầu vào, t_j là ngõ ra mong muốn của một lớp và $K = f \times P$, trong đó f là một tỷ số cho trước. Sau khi huấn luyện mạng, chúng tôi sẽ sử dụng mạng này để trích đặc trưng của ảnh khuôn mặt. Bộ phân loại Nearest Neighbor sẽ được sử dụng để nhận dạng ảnh đầu vào trong điều kiện

SSPP. Ảnh khuôn mặt trong tập dữ liệu ORL sẽ được sử dụng trong mô phỏng này. Chúng tôi sẽ so sánh kết quả nhận dạng của mạng InceptionV3 với tập dữ liệu ORL khi sử dụng hai hàm mất mát ở lớp đầu ra: cross-entropy và LT-MHD. Bảng 6.1 mô tả về tỷ lệ nhận dạng của mạng InceptionV3 với tập dữ liệu ORL khi sử dụng hai hàm mất mát. Kết quả cho thấy việc áp dụng hàm mất mát LT-

Bảng 6.1: So sánh tỷ lệ nhận dạng của mạng InceptionV3 khi sử dụng các hàm mất mát khác nhau

Loss function	Cross-entropy	LT-MHD
Recognition rate	19.44%	62.78%
Increase		43.34%

MHD thay cho hàm cross-entropy giúp tỷ lệ nhận dạng của mạng CNN này với tập dữ liệu ORL tăng lên 43%.

Tuy nhiên tỷ lệ nhận dạng chỉ đạt 62.78% là một kết quả chưa thật sự tốt. Điều này có thể được giải thích là vì mạng CNN của chúng tôi chỉ được huấn luyện với một tập dữ liệu ảnh nhỏ (chỉ bao gồm 40 ảnh) thay vì một tập dữ liệu khuôn mặt lớn. Việc này dẫn đến mạng CNN mà chúng tôi đề xuất không thể học tốt cách trích đặc trưng của ảnh khuôn mặt như các mô hình khác.

CHƯƠNG 7 KẾT LUẬN

Các kết quả đạt được trong nghiên cứu

Điều kiện đơn mẫu là một điều kiện quan trọng trong các ứng dụng thực tế mà các phương pháp nhận dạng khuôn mặt cần giải quyết. Trong nghiên cứu này chúng tôi đã hệ thống lại một số nhóm phương pháp nhận dạng khuôn mặt đã được đề xuất để giải quyết bài toán đơn mẫu. Việc phân tích ưu nhược điểm của các nhóm phương pháp này đã cho thấy nhóm phương pháp nào cũng có những hạn chế cần khắc phục. Vì vậy một nghiên cứu nhằm khắc phục những hạn chế của một nhóm phương pháp là rất cần thiết. Nghiên cứu này đưa ra giải pháp nhằm khắc phục những hạn chế của nhóm phương pháp nhận dạng khuôn mặt dựa trên đặc trưng cục bộ là các pixel cạnh bao gồm tỷ lệ nhận dạng và độ phức

tạp tính toán của các phương pháp. Những đóng góp mới của nghiên cứu này có thể được tóm tắt như sau.

- Nghiên cứu đã đề xuất một độ đo mới, khoảng cách LT-MHD để đo sự khác nhau giữa hai tập hợp đặc trưng. Các kết quả đã cho thấy khoảng cách LT-MHD có thể được sử dụng hiệu quả với nhiều loại đặc trưng khác nhau của ảnh khuôn mặt. Điều này cho thấy khoảng cách LT-MHD có thể được áp dụng cho những phương pháp nhận dạng khuôn mặt khác sử dụng các tập đặc trưng khác nhau.
- Dựa trên khoảng cách LT-MHD, hai phương pháp nhận dạng khuôn mặt trong điều kiện đơn mẫu là LT-LHD và LT-MMHD đã được đề xuất. Các kết quả mô phỏng về tỷ lệ nhận dạng khuôn mặt của hai phương pháp LT-LHD và LT-MMHD đã chứng minh rằng việc sử dụng khoảng cách LT-MHD thay cho khoảng cách Hausdorff trung bình sẽ giúp cải thiện 2-10% tỷ lệ nhận dạng chính xác tùy từng điều kiện của ảnh đầu vào. Các kết quả này có thể mở rộng áp dụng cho một số phương pháp nhận dạng khuôn mặt khác sử dụng khoảng cách Hausdorff trung bình [15-22] để giúp làm tăng tỷ lệ nhận dạng của các phương pháp này.
- Tỷ lệ nhận dạng của hai phương pháp LT-LHD và LT-MMHD cho kết quả khá tốt khi so sánh với một số các phương pháp nhận dạng khuôn mặt trong điều kiện đơn mẫu những năm gần đây trong cùng điều kiện mô phỏng. Đặc biệt, phương pháp LT-LHD cho tỷ lệ nhận dạng cao hơn 2-11% so với các phương pháp được đề xuất trong khoảng 5 năm gần đây.
- Để cải thiện độ phức tạp tính toán cho hai phương pháp LT-LHD và LT-MMHD, nghiên cứu này đã thực hiện một phân tích sâu về các phương pháp trong lĩnh vực CAD/CAM/CAE về giảm độ phức tạp tính toán cho phép tính khoảng cách Hausdorff. Dựa trên phân tích sâu này, nghiên cứu đã áp dụng hai phương pháp EARLYBREAK và LSS để làm giảm độ phức tạp tính toán cho hai phương pháp LT-LHD và LT-MMHD.

Việc chứng minh bằng toán học đã cho thấy sự hiệu quả trong việc giảm độ phức tạp của các phương pháp LT-LHD và LT-MMHD khi được áp dụng các phương pháp như EARLYBREAK và LSS. Các kết quả mô phỏng cũng cho kết quả tương tự khi phương pháp LT-MMHD và LT-LHD có độ phức tạp tính toán giảm lần lượt 17% và 67% và thời gian tính toán giảm lần lượt là 16% và 65%. Các kết quả này cũng có thể được áp dụng để cải thiện độ phức tạp tính toán cho các phương pháp [15-22].

- Ngoài ra trong nghiên cứu này, chúng tôi cũng trình bày phương pháp kết hợp giữa khoảng cách LT-MHD cùng một mạng CNN để trích đặc trưng của khuôn mặt. Khoảng cách LT-MHD được sử dụng như một hàm mất mát ngõ ra của mạng CNN. Các kết quả mô phỏng cho thấy việc dùng hàm mất mát ngõ ra là khoảng cách LT-MHD thay vì hàm cross-entropy đã làm tăng tỷ lệ nhận dạng khuôn mặt của mạng CNN lên 43%.

Hướng phát triển

Từ các kết quả của nghiên cứu này, các nghiên cứu sau có thể áp dụng khoảng cách LT-MHD để cải thiện tỷ lệ nhận dạng cho các phương pháp sử dụng khoảng cách Hausdorff trung bình; cũng như sử dụng các phương pháp như EARLYBREAK và LSS để làm giảm độ phức tạp như cách thức từ nghiên cứu này đề xuất. Bên cạnh đó, các nghiên cứu khác có thể tiếp tục sử dụng cấu trúc mạng CNN kết hợp cùng khoảng cách LT-MHD như nghiên cứu này đề xuất nhưng được huấn luyện với một tập dữ liệu lớn hơn để đề xuất một phương pháp nhận dạng khuôn mặt dựa trên học sâu trong điều kiện đơn mẫu có tỷ lệ nhận dạng tốt hơn.

DANH MỤC CÔNG TRÌNH ĐÃ CÔNG BỐ

Tạp chí quốc tế

1. Chau Dang-Nguyen and Tuan Do-Hong, "Reducing Computational Complexity of New Modified Hausdorff Distance Method for Face Recognition Using Local Start Search," *International Journal of Electrical and Electronic Engineering and Telecommunications*, 2021. ISSN: 2319-2518. **(Indexed by Scopus)**.
2. C. Dang-Nguyen, T. Do-Hong, "Application of EARLYBREAK for Line Segment Hausdorff Distance for Face Recognition," *Advances in Science, Technology and Engineering Systems Journal*, vol. 5, no. 4, pp. 557-566, 2020. ISSN: 2415-6698. doi: 10.25046/aj050466. **(Indexed by Scopus)**.

Tạp chí trong nước

1. Chau Dang and Tuan Do, "A modification of Modified Hausdorff Distance method applying for face recognition," *Science and Technology Development Journal*, vol. 20, no. K3, pp. 126-131, 2017. ISSN: 1859-0128. doi: 10.32508/stdj.v20iK3.1102. **(Tạp chí thuộc danh mục tính điểm theo quy định của Hội đồng chức danh giáo sư nhà nước)**.
2. Chau Dang and Tuan Do, "A modification of line Hausdorff distance for face recognition to reduce computational cost," *Science and Technology Development Journal*, vol. 20, no. K3, pp. 152-158, 2017. ISSN: 1859-0128. doi: 10.32508/stdj.v20iK3.1106. **(Tạp chí thuộc danh mục tính điểm theo quy định của Hội đồng chức danh giáo sư nhà nước)**.
3. Dang Nguyen Chau and Do Hong Tuan, "Overview of Face Recognition based on Edge Feature," *Journal of Science and Technology – University of DaNang*, vol. 5, no. 114, pp. 21-26, 2017. ISSN: 1859-1531 **(Tạp chí thuộc danh mục tính điểm theo quy định của Hội đồng chức danh giáo sư nhà nước)**.

Kỷ yếu hội nghị quốc tế

1. C. Dang-Nguyen and T. Do-Hong, "Robust Line Hausdorff Distance for Face Recognition," 2019 International Symposium on Electrical and Electronics Engineering (ISEE), Ho Chi Minh, Vietnam, 2019, pp. 103-107, doi: 10.1109/ISEE2.2019.8921218.

Ghi chú:

- 1. Liệt kê các bài báo, công trình đã công bố của tác giả về nội dung của đề tài, theo trình tự thời gian công bố (tài liệu mới nhất được liệt kê đầu tiên) theo định dạng của IEEE (đối với luận án nhóm ngành kỹ thuật), hoặc APA (đối với luận án nhóm ngành quản lý). Trong trường hợp, NCS có các công bố trước khi trúng tuyển NCS hoặc dự bị tiến sĩ, danh mục này phải được phân chia thành hai đề mục riêng: A. Trước khi trúng tuyển NCS (hoặc dự bị tiến sĩ); và B. Sau khi trúng tuyển NCS (hoặc dự bị tiến sĩ).*
- 2. Trong từng đề mục, danh mục công trình đã công bố phải được phân loại thành các mục chính (nếu có) như sau: tạp chí quốc tế, tạp chí trong nước, kỷ yếu hội nghị quốc tế, kỷ yếu hội nghị trong nước, đề tài nghiên cứu khoa học, ...*
- 3. File này được định dạng sẵn theo kiểu in sách (booklet), bạn chỉ cần Save as thành file khác, xóa các phần không cần thiết và tiến hành soạn thảo nội dung. Sau khi soạn thảo xong, bạn sử dụng máy in 2 mặt để in trên giấy khổ A4. Việc in sẽ tự động sắp xếp theo dạng đóng sách và tạo ra 4 trang trên một tờ giấy A4.*