

ĐÁNH GIÁ HIỆU NĂNG CỦA PHƯƠNG PHÁP PHÂN TÍCH THÀNH PHẦN CHÍNH PCA TRONG NHẬN DẠNG KHUÔN MẶT CÓ BIẾN ĐỔI VỀ SẮC THÁI

Dương Ngọc Vân Khanh¹, Nguyễn Bảo Ân²

AN EVALUATION ON PERFORMANCE OF PCA IN FACE RECOGNITION WITH EXPRESSION VARIATIONS

Duong Ngoc Van Khanh¹, Nguyen Bao An²

Tóm tắt – Các phương pháp nhận dạng mặt người dựa trên vẻ ngoài thường gặp các khó khăn khi khuôn mặt được nhận dạng có sự thay đổi về sắc thái như khóc, cười, há miệng... Trong trường hợp này, các phương pháp nhận dạng toàn phần có hiệu năng tốt hơn. Bài báo này trình bày một số đánh giá dựa trên phương pháp nhận dạng toàn phần trên mặt người có biến đổi về sắc thái, sử dụng phương pháp rút gọn số chiều PCA và các thuật toán phân lớp. Kết quả thực nghiệm cho thấy độ chính xác phân lớp tốt nhất khi sử dụng rất ít eigenvectors và thuật toán KNN (khi $k=1$) cho kết quả tốt hơn SVM.

Từ khóa: nhận dạng khuôn mặt có biến đổi sắc thái, phân tích thành phần chính, thuật toán KNN

Abstract – Appearance-based recognition methods often encounter difficulties when the input images contain facial expression variations such as laughing, crying or wide mouth opening. In these cases, holistic methods give better performance than appearance-based methods. This paper presents some evaluation on face recognition under variation of facial expression

using the combination of PCA and classification algorithms. The experimental results showed that the best accuracy can be obtained with very few eigenvectors and KNN algorithm (with $k=1$) performs better than SVM in most test cases.

Keywords: face recognition under expression variations, principle component analysis, KNN algorithm

I. GIỚI THIỆU

Nhận dạng khuôn mặt (facial recognition) là một bài toán tiêu biểu của học máy (machine learning) và nhận dạng mẫu (pattern recognition). Thao tác nhận dạng thường được cài đặt bằng một thuật toán phân lớp (classification) dưới mô hình học có giám sát (supervised learning). Một cách tổng quát, ảnh đầu vào luôn chịu ảnh hưởng bởi một hoặc nhiều sự biến đổi so với ảnh được lưu trong cơ sở dữ liệu. Một số biến đổi có thể kể đến là điều kiện ánh sáng (illumination variation – trong đó bao gồm hướng và cường độ của nguồn sáng), góc chụp (pose variation), trang điểm (make-up), tuổi tác (aging), biểu cảm của khuôn mặt (facial expression),... Các nghiên cứu nhận dạng mặt người đều cố gắng thích nghi với nhiều sự biến đổi nhất có thể. Bài báo này trình bày kết quả việc ứng dụng phương pháp phân tích thành phần chính Principal Component Analysis (PCA) trong rút gọn số chiều dữ liệu để nhận dạng khuôn mặt người có biến đổi về sắc thái với nhiều thuật toán phân lớp khác nhau. Kết quả cho thấy khi xử lý rút gọn số chiều bằng PCA, thuật toán phân lớp K-nearest neighbors (KNN)

^{1,2}Bộ môn Công nghệ Thông tin, Khoa Kỹ thuật và Công nghệ, Trường Đại học Trà Vinh

Ngày nhận bài: 21/12/2017; Ngày nhận kết quả bình duyệt: 22/02/2018; Ngày chấp nhận đăng: 30/7/2018

Email: vankhanh@tvu.edu.vn

^{1,2}School of Information Technology, School of Engineering and Technology, Tra Vinh University

Received date: 21st December 2017; Revised date: 22nd February 2018; Accepted date: 30th July 2018

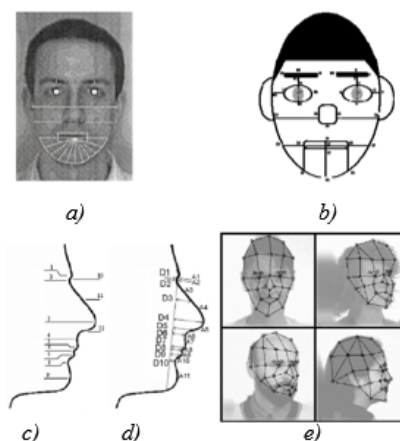
(với $k=1$) cho kết quả trong tập dữ liệu kiểm thử tốt hơn so với thuật toán Support Vector Machine (SVM) trong hầu hết thí nghiệm.

II. TỔNG QUAN NGHIÊN CỨU

A. Các kỹ thuật nhận dạng khuôn mặt

Các kỹ thuật nhận dạng khuôn mặt có thể chia thành ba nhóm chính: nhận dạng từ ảnh tĩnh, nhận dạng từ chuỗi ảnh động (video) và nhận dạng theo mô hình ba chiều (với ảnh của đối tượng được ghi nhận bởi một camera hồng ngoại 3D). Phạm vi bài báo này chỉ trình bày chi tiết phương pháp nhận dạng ảnh tĩnh. Các kỹ thuật nhận dạng khuôn mặt từ ảnh tĩnh có thể chia ra hai nhóm: nhận dạng dựa vào đặc trưng (từng phần – feature based recognition) và nhận dạng toàn phần (holistic).

1) *Các kỹ thuật nhận dạng dựa vào đặc trưng (feature based)*: Trong các kỹ thuật này, người ta thường cố gắng trích ra những đặc trưng trên khuôn mặt như mũi, mắt, miệng, chân mày và tính mối liên hệ về hình học giữa các điểm này, sau đó rút gọn ảnh đầu vào bằng một vector biểu thị đặc trưng hình học của khuôn mặt. Tiếp theo, chúng ta sử dụng các vector này để so khớp trong bộ nhận dạng. Cách rút trích đặc trưng khuôn mặt sử dụng trong nhiều phương pháp khác nhau được biểu diễn trong các Hình 1 và 2. Năm 1993, Brunelli và Poggio [1] xây dựng một mô hình nhận dạng gồm 35 đặc trưng hình học của khuôn mặt từ một cơ sở dữ liệu khuôn mặt của 47 người. Mô hình này cho tần số nhận dạng khoảng 90%. Năm 1996, Cox và cộng sự [4] xây dựng một mô hình phức tạp hơn là sử dụng một vector 30 chiều trích xuất từ mô hình 35 đặc trưng và cho tần số nhận dạng đến 95%. Một cách tiếp cận khác là sử dụng đồ thị co giãn (elastic bunch graph) để biểu thị đặc trưng của khuôn mặt [2], một số điểm chuẩn trên khuôn mặt được chọn, các cạnh nối các điểm chuẩn này sẽ tạo thành một đồ thị dạng lưới bao trùm hết khuôn mặt, khi có một khuôn mặt mới cần nhận dạng, đồ thị cho khuôn mặt mới sẽ được hình thành bằng thuật toán Elastic Bunch Graph Matching. Phương pháp này cho độ chính xác lên đến 98%. Nhưng cách tiếp cận dễ hơn đã được đề xuất bởi Liposcak và Loncaric [3] với vector 21 đặc trưng sử dụng phương pháp



Hình 1: a) Các đặc trưng hình học - (Nguồn: Theo R. Brunelli và T. Poggio [1])

b) Mô hình 35 đặc trưng - (Nguồn: Theo I. J. Cox và cộng sự [4])

c) Lưới các đặc trưng - (Nguồn: Theo L. Wiskott [2])

d) Mô hình 12 điểm đặc trưng - (Nguồn: Theo Z. Liposcak [3])

e) Mô hình 21 vector đặc trưng - (Nguồn: Theo Z. Liposcak [3])

lọc subspace filtering và cho độ chính xác khoảng 90%.

Các phương pháp nhận dạng dựa trên đặc trưng, do chỉ trích xuất các đặc trưng từng phần của khuôn mặt, có ưu điểm là mạnh mẽ với sự thay đổi của vị trí khuôn mặt trong ảnh, kích thước của ảnh cũng như hướng và điều kiện ánh sáng và tốc độ so khớp khi nhận dạng nhanh. Tuy nhiên, khó khăn của các phương pháp này là sự phức tạp trong các thao tác xử lý ảnh để trích xuất các đặc trưng và xác định mức độ quan trọng của từng đặc trưng.

2) *Các kỹ thuật nhận dạng toàn phần (holistic)*: Kỹ thuật nhận dạng toàn phần dùng toàn bộ khuôn mặt để làm dữ liệu đầu vào. Để nhận dạng, người ta thường dùng các thuật toán máy học như SVM (Support Vector Machine) [5], mạng Neuron, KNN (K nearest neighbors – K láng giềng gần nhất)... Thông thường, chúng ta phải dùng một hàm đo độ tương tự giữa hai đối tượng dữ liệu, phổ biến nhất là khoảng cách Euclidean (Euclidean distance). Tuy nhiên, do ảnh có số

chiều lớn (trên dưới 100x100) nên cần có một phương pháp rút gọn số chiều để đưa dữ liệu về một không gian có số chiều nhỏ hơn so với không gian gốc và tiến hành các thao tác nhận dạng trên dữ liệu mới này mà không ảnh hưởng đến kết quả phân lớp (thậm chí mang lại hiệu quả cao hơn khi tiến hành trên không gian gốc). Hai phương pháp rút gọn số chiều thường được sử dụng là PCA (Principle Component Analysis) [6], [7] và LDA (Linear Discriminant Analysis) [8].

Ưu điểm của phương pháp nhận dạng toàn phần là lấy toàn bộ dữ liệu của khuôn mặt làm dữ liệu nhận dạng, tránh mất mát thông tin. Tuy nhiên, điều này cũng hạn chế khi một số phương pháp xem rằng tất cả pixel trong ảnh đều có độ quan trọng như nhau. Hơn nữa, độ phức tạp tính toán khi tính độ tương quan giữa toàn bộ các ảnh cũng rất cao cũng như hiệu năng của nhận dạng khi điều kiện ánh sáng, góc chụp thay đổi cũng không tốt.

Với dữ liệu mặt người có sự biến đổi về sắc thái, chúng tôi cho rằng sự sai biệt giữa phần của khuôn mặt tạo nên các sắc thái khác nhau, ví dụ như miệng và mắt của một người khi cười sẽ rất khác biệt so với khi khóc. Do đó, chúng ta sẽ rất khó tìm được sự tương quan khi sử dụng phương pháp nhận dạng dựa trên đặc trưng. Ngược lại, khi sử dụng phương pháp nhận dạng toàn phần, các biến đổi về sắc thái này được kì vọng không ảnh hưởng nghiêm trọng đến độ đo sự tương tự giữa các ảnh. Nếu chiếu lên không gian tọa độ, ta kì vọng rằng các ảnh của cùng một người với biến đổi sắc thái khác nhau vẫn nằm gần nhau. Đó là lí do chúng tôi chọn PCA để xử lí trường hợp ảnh khuôn mặt có biến đổi sắc thái, vì PCA là phương pháp rút gọn số chiều nhưng vẫn duy trì sự phân bố của dữ liệu rất tốt. Bài báo này nhằm đánh giá hiệu năng của phương pháp PCA và so sánh giữa thuật toán KNN và SVM trong phân lớp dữ liệu mặt người có biến đổi sắc thái trong một số kịch bản khác nhau.

B. Phương pháp PCA (Principle Component Analysis)

Phân tích thành phần chính (Principle Component Analysis – PCA) được đề xuất lần đầu tiên bởi Karl Pearson vào năm 1901 [8] và được ứng

dụng trong các lĩnh vực khác nhau dưới nhiều tên gọi khác nhau. Trong phân tích dữ liệu, PCA được sử dụng rộng rãi để khám phá dữ liệu (data exploring), rút gọn dữ liệu (data reduction), nén dữ liệu (data compression) đối với dữ liệu có số chiều lớn, khó trực quan hóa và tính toán.

Mục đích chính của PCA là giảm số chiều dữ liệu với các mục tiêu: i) tìm một không gian mới với số chiều ít hơn so với không gian gốc nhưng vẫn giữ được khả năng biểu diễn phân bố của dữ liệu tương đương hoặc tốt hơn trong không gian cũ, tức là đảm bảo độ biến thiên (variability) của dữ liệu trên số chiều mới; ii) các trục tọa độ trong không gian mới phải trực giao với nhau và được tính toán dựa vào dữ liệu quan sát được ở không gian cũ; iii) kì vọng đặt ra với không gian mới là tính tương quan của dữ liệu được thể hiện tốt hơn trong không gian gốc. Như vậy, ta phải tìm các vector trực giao ω sao cho khi ta chiếu dữ liệu lên các vector này thì phương sai của dữ liệu được tối đa hóa.

Với X là ma trận dữ liệu gốc ta muốn tối đa hóa $\text{Var}(\omega^T X)$, với ràng buộc $\|\omega\|=1$, bài toán tối đa hóa trên có hàm mục tiêu $J(\omega)=\text{Var}(\omega^T X)$ (1)

Theo công thức của phương sai, ta có thể thế vào (1), với μ là trung bình của X

$$J(\omega) = E(\omega^T X - \omega^T \mu)^2 = E(\omega^T X - \omega^T \mu)(X^T \omega - \mu^T \omega) = \omega^T E(X - \mu)(X - \mu)^T \omega = \omega^T \Sigma$$

với $\Sigma = E(X - \mu)(X - \mu)^T$ là ma trận hiệp phương sai.

Với mục tiêu là cực đại hóa $J(\omega)$ theo biến ω , với ω được chuẩn hóa sao cho thỏa ràng buộc $\|\omega\|=1$, điều này có thể được giải quyết bởi thao tác tối ưu hóa Lagrangian với các ràng buộc đã nêu: $L(\omega, \lambda) = \omega^T \Sigma \omega - \lambda(\omega^T \omega - 1)$.

Tạo phương trình $L'(\omega, \lambda) = 0$ với $L'(\omega, \lambda)$ là đạo hàm của $L(\omega, \lambda)$ theo biến ω , ta có:

$$\frac{\partial L(\omega, \lambda)}{\partial \omega} = 2\Sigma\omega - 2\lambda\omega = 0 \leftrightarrow \Sigma\omega = \lambda\omega$$

Lúc này, mục tiêu của bài toán trở về tìm biến ω thỏa mãn $\Sigma\omega = \lambda\omega$. Dựa vào định nghĩa của eigenvector và eigenvalue, ta thấy, mục tiêu là tìm các eigenvector ω và eigenvalue của ma trận hiệp phương sai Σ . Với dữ liệu có n chiều, ta có thể tìm được n eigenvector và n eigenvalue. Tuy nhiên,

ta không cần sử dụng hết tất cả các eigenvector mà chỉ cần chọn một số eigenvector sao cho tại đó eigenvalue đạt một giá trị tương đối cao. Điều này có thể thực hiện bằng cách sắp xếp lại các eigenvector theo thứ tự giảm dần của eigenvalue tương ứng, sau đó chọn ra n eigenvectors để đại diện cho không gian mới, với n rất nhỏ so số chiều của không gian gốc. Ta gọi các eigenvector được chọn là FeatureVector, vậy:

$$FeatureVector = (eig_1, eig_2, eig_3, \dots, eig_n)$$

C. Thủ thuật Gram Matrix

Giả sử ta có bộ dữ liệu ảnh với kích thước 200×200 (40.000 chiều), vậy kích thước của ma trận hiệp phương sai $\Sigma = E(X - \mu)(X - \mu)^T$ là 40000^2 . Trong thực tế, ta không thể khởi tạo một ma trận có số chiều cực lớn như vậy khi lập trình. Hơn nữa, với tập dữ liệu có N mẫu (N rất nhỏ so với số chiều của dữ liệu), chúng ta chỉ cần tối đa $N-1$ eigenvectors. Để giải quyết vấn đề này, ta sử dụng thủ thuật Gram Matrix.

Ta biết $\Sigma = E(X - \mu)(X - \mu)^T$. Ta phải giải bài toán tìm v và λ sao cho: $\Sigma v = \lambda v \leftrightarrow XX^T v = \lambda v$.

Nhân cả hai vế cho X^T ta có: $X^T XX^T v = \lambda X^T v$.

Đặt $v' = X^T v$, ta được: $X^T X v' = \lambda v'$. Vậy, bài toán được đưa về tìm eigenvector v' . Ma trận $X^T X$ được gọi là ma trận Gram. Kích thước của nó không phụ thuộc vào số chiều của dữ liệu nhưng phụ thuộc vào số mẫu dữ liệu trong bộ dữ liệu đào tạo. Số chiều của nó bằng $N \times N$, với N là số đối tượng dữ liệu trong tập dữ liệu.

Vậy, thay vì tìm các eigenvectors v cho một ma trận hiệp phương sai khổng lồ, ta chỉ cần tìm các eigenvector v' cho ma trận Gram có số chiều $N \times N$. Như vậy, ta chỉ cần tìm tối đa $N-1$ eigenvector để biểu diễn không gian mới. Vấn đề còn lại là làm sao phục hồi lại được v từ v'

Ta có:

$$XX^T v = \lambda v \quad (1)$$

$$v' = X^T v \quad (2)$$

Thế (2) vào (1) ta được $Xv' = \lambda v$, vậy $v = Xv'$ (ta không quan tâm đến hằng số λ vốn kéo dài v ra λ lần, vì $\|v\|=1$)

III. CÀI ĐẶT THỰC NGHIỆM

Thử nghiệm được cài đặt bằng Matlab. Dữ liệu thử nghiệm được lấy từ bộ dữ liệu Face Expression Database (CMU AMP Lab) [9] bao gồm ảnh gương mặt của 13 người khác nhau với nhiều nét biểu cảm khác nhau, mỗi người có 74 ảnh với kích thước 64×64 pixels (Hình 2). Thử nghiệm được tiến hành như sau:

Bước 1: Chọn 5 ảnh đầu tiên của mỗi người làm dữ liệu đào tạo, vậy tập dữ liệu Dtraining có $13 \times 5 = 65$ ảnh.

Bước 2: Thực hiện PCA trên tập Dtraining để tìm các eigenvector và eigenvalue, ta có tất cả $65-1 = 64$ eigenvectors và eigenvalues, ảnh của các eigenvector đầu tiên thể hiện trong Hình 3.




Hình 2: Một số ảnh trong bộ dữ liệu thử nghiệm (Nguồn: *Electrical & Computer engineering* [9])

Bước 3: Lấy 3 eigenvector quan trọng nhất (có eigenvalue lớn nhất) biểu diễn không gian mới. Vậy, dữ liệu được rút gọn từ $64 \times 64 = 4096$ chiều xuống còn 3 chiều.


Bước 4: Chiếu tập dữ liệu đào tạo lên không gian ba chiều vừa hình thành, ta được 65 mẫu dữ liệu ba chiều. Hình 4 thể hiện phân bố của các mẫu dữ liệu đào tạo ba lớp 1, 2, và 3 trong không gian ba chiều. Dễ thấy, trong không gian đã rút gọn, phân bố của các đối tượng tương đối tách biệt giữa các lớp.

Bước 5: Dùng tập 13×69 ảnh còn làm tập dữ liệu kiểm thử, ta cũng rút gọn bộ dữ liệu này bằng cách chiếu lên không gian ba chiều đã chọn. Phân bố của toàn bộ 3×75 ảnh của ba lớp đầu tiên khi chiếu lên không gian ba chiều được biểu diễn ở Hình 4. Ta có thể thấy ảnh của ba lớp phân bố ở ba cụm phân biệt rất rõ ràng. Điều này chứng tỏ không gian mới, dù chỉ ba chiều, thể hiện sự biến thiên của dữ liệu rất tốt và có thể làm tăng hiệu quả phân lớp.



Hình 3: Ảnh trung bình và ảnh của các eigenvector.

(Nguồn: Kết quả thí nghiệm)



Hình 4: a) Hình chiếu trong không gian ba chiều của dữ liệu đào tạo ba lớp 1, 2 và 3

b) Phân bố của tất cả các ảnh thuộc ba lớp 1, 2 và 3

(Nguồn: Kết quả thí nghiệm)


Bước cuối cùng là sử dụng thuật toán KNN để phân lớp: dựa vào khoảng cách Euclidean trong không gian ba chiều, ta có thể gán nhãn cho một ảnh đang xét dựa vào nhãn chiếm đa số trong k láng giềng gần nhất của nó. Do số lớp tương đối lớn, khi sử dụng $k > 1$ sẽ gây tình trạng cạnh tranh giữa các nhãn dữ liệu được gán, do đó chúng tôi chọn $k=1$ trong tất cả thí nghiệm.

IV. KẾT QUẢ THỰC NGHIỆM VÀ THẢO LUẬN

A. Lựa chọn số eigen vector tối ưu cho PCA

Để chọn số eigen vector tối ưu cho PCA, chúng tôi thử nghiệm thay đổi số eigen vectors từ 2 đến 30 và sử dụng hai thuật toán KNN và SVM để phân lớp và được kết quả như trong Hình 5. Thực nghiệm cho thấy PCA không cần quá nhiều eigen

vectors để tái tạo dữ liệu nhưng vẫn đảm bảo tính chính xác của phép phân lớp. Trong tất cả 64 eigenvector có được từ bộ dữ liệu đào tạo, với thuật toán KNN, ta chỉ cần sử dụng 4 vectors để có được kết quả tốt nhất, tuy nhiên với thuật toán SVM khi tăng số eigenvector lên trên 10 vectors, hiệu năng phân lớp sẽ giảm dần.



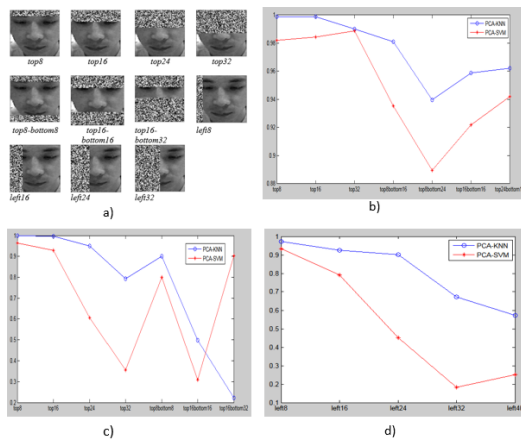
Hình 5: Độ chính xác phân lớp khi sử dụng số eigenvector khác nhau.

(Nguồn: Kết quả thí nghiệm)

B. Các đánh giá hiệu năng trên tập dữ liệu không đầy đủ

Để đánh giá hiệu năng của PCA trên các bộ dữ liệu khuôn mặt không hoàn chỉnh và với các thuật toán phân lớp khác nhau, chúng tôi tạo các bộ dữ liệu khuôn mặt mới dựa vào tập dữ liệu AMP. Trong đó, tất cả các ảnh sẽ được che một phần bằng màu đen hoặc thêm nhiễu ngẫu nhiên theo cả hai hướng đứng và ngang, tên và ví dụ các bộ dữ liệu được thể hiện trong Hình 6a (con số trong tên bộ dữ liệu thể hiện số cột/dòng bị che).

Sau khi tạo bộ dữ liệu không hoàn chỉnh, chúng tôi thực hiện theo quy trình đã mô tả ở trên và phân lớp theo bằng cả hai thuật toán KNN ($k=1$) và SVM. Độ chính xác của các thao tác thể hiện ở Hình 6. Đối với ảnh bị che theo chiều ngang, trong cả hai trường hợp khi bị che khoảng 30% phía trên, cả hai thuật toán đều cho kết quả trên 90%. Khi tăng phần khuôn mặt bị che lên đến 50%, độ chính xác của bộ ảnh bị che bằng nhiễu ngẫu nhiên giảm đi đáng kể, đặc biệt



Hình 6: a) Ảnh khuôn mặt che bằng nhiễu ngẫu nhiên; so sánh độ chính xác phân lớp với dữ liệu khuôn mặt bị che ngang bằng màu đen (a), che ngang bằng nhiễu ngẫu nhiên (b) và che bên trái bằng nhiễu ngẫu nhiên (c)
(Nguồn: Kết quả thí nghiệm)

là với thuật toán SVM. Còn đối với bộ ảnh bị che theo chiều dọc bên trái, khi phần bị che lên đến 25%, thuật toán KNN vẫn cho độ chính xác trên 90%, trong khi SVM chỉ cho độ chính xác khoảng 80%.

Nhìn chung, kết quả thực nghiệm cho thấy thuật toán KNN cho hiệu năng phân lớp khuôn mặt tốt nhất khi $k=1$ và trong phần lớn trường hợp KNN đều cho kết quả tốt hơn SVM. Đối với các bộ dữ liệu khuôn mặt không hoàn chỉnh, dễ thấy trường hợp khuôn mặt bị che theo chiều dọc ảnh hưởng lớn đến khả năng phân lớp hơn trường hợp vùng khuôn mặt bị che theo chiều ngang và vùng bị che bằng nhiễu ngẫu nhiên sẽ ảnh hưởng lên hiệu năng phân lớp lớn hơn so với bị che bằng màu đen.

V. KẾT LUẬN

Bài báo này trình bày một phương pháp hữu hiệu để nhận dạng khuôn mặt có độ chính xác đáng kể khi thực thi trên bộ dữ liệu khuôn mặt có biến đổi về sắc thái. Thực nghiệm chứng tỏ khi sử dụng PCA để rút gọn số chiều và đưa dữ liệu gốc về một không gian ít chiều hơn, phân bố của dữ liệu vẫn đảm bảo tính biến thiên như kì vọng. Đặc biệt với bộ dữ liệu ảnh có biến đổi về sắc thái khuôn mặt, dữ liệu được rút gọn thuộc

các lớp khác nhau phân bố ở các cụm rất rõ ràng và tách biệt trong không gian mới, điều này giúp tăng hiệu quả phân lớp so với trong không gian gốc. Khi tiến hành phân lớp với hai thuật toán KNN và SVM, thuật toán KNN với $k=1$ cho kết quả tốt trong hầu hết trường hợp. Sau khi thực hiện PCA, độ phức tạp tính toán giảm đi đáng kể (với bộ dữ liệu thử nghiệm, có thể giảm từ 4096 chiều về ba chiều), nhờ đó có thể dễ dàng cài đặt ở các thiết bị có hiệu năng tính toán thấp và cần thời gian đáp ứng nhanh. Tuy hiệu năng phân lớp ở các trường hợp dữ liệu không hoàn chỉnh vẫn chưa cao nhưng sự kết hợp giữa PCA và KNN vẫn là một cách tiếp cận rất đáng quan tâm nghiên cứu như một mô hình tham chiếu trong các nghiên cứu nhận dạng mặt người.

TÀI LIỆU THAM KHẢO

- [1] Brunelli R, Poggio T. Face recognition: features versus templates. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1993;15:1042–1052.
- [2] Wiskott L, Fellous J M, Krüger N, von der Malsburg C. Face Recognition by Elastic Bunch Graph Matching. In: L C Jain, U Halici, I Hayashi, S B Lee, , Jae-Ho, editors. *Intelligent Biometric Techniques in Fingerprint and Face Recognition*. CRC Press; 1999. p. 355–396.
- [3] Liposcak Z, Loncaric S. A scale-space approach to face recognition from profiles. In: *Proceedings of the 8th International Conference on Computer Analysis of Images and Patterns*. London, UK: Springer- Verlag; 1999. p. 243–250.
- [4] Cox I J Ghosn J, Yianilos P N. Feature- based face recognition using mixture-distance. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*; 1996. p. 209–216.
- [5] Cortes C, Vapnik V. Support-vector networks. *Machine Learning*. 1995;20(3):273–297.
- [6] Jain A K, Dubes R C. *Algorithms for Clustering Data*. vol. 152. New Jersey: Prentice-Hall; 1988.
- [7] Fukunaga K. *Introduction to Statistical Pattern Recognition*. 2nd ed. MA: Academic Press; 1990.
- [8] Pearson K. On Lines and Planes of Closest Fit to Systems of Points in Space. *Philosophical Magazine*. 1901;p. 1042–1052.
- [9] Electrical & Computer Engineering. *Face Authentication Project* ; 2018. Truy cập từ: <http://chenlab.ece.cornell.edu/projects/FaceAuthentication/download.html> [Ngày truy cập: 14/11/2017].