

NHẬN DẠNG KHUÔN MẶT DỰA TRÊN MÔ HÌNH XỬ LÝ SONG SONG VÀ PHÂN TÁN MAPREDUCE

Phan Anh Cang¹, Lê Hoàng Sơn², Phan Thượng Cang³

¹ Khoa Công nghệ Thông tin, Trường Đại học Sư phạm Kỹ thuật Vĩnh Long

² Khoa Công nghệ Thông tin, Trường CĐ Kinh tế - Tài chính Vĩnh Long

³ Khoa Công nghệ Thông tin, Trường Đại học Cần Thơ

cangpa@vlute.edu.vn, lhson87@gmail.com, ptcang@cit.ctu.edu.vn

TÓM TẮT: Các phương pháp nhận dạng khuôn mặt đang được ứng dụng rất rộng rãi và đem lại các lợi ích to lớn cho người sử dụng trong các hệ thống xác thực, bảo mật, giám sát tội phạm,... Bên cạnh độ chính xác, các phương pháp nhận dạng khuôn mặt truyền thống phải đối mặt với vấn đề đó là tiêu tốn nhiều thời gian để nhận dạng, khả năng tính toán lớn và có thể áp dụng cho các hệ thống phân tán với môi trường dữ liệu lớn đang phát triển hiện nay để xử lý và phân tích dữ liệu một cách hiệu quả. Để giải quyết vấn đề này, chúng tôi đề xuất một phương pháp rút trích đặc trưng khuôn mặt bằng cách sử dụng kỹ thuật Gabor wavelet và mô hình xử lý song song MapReduce ở giai đoạn huấn luyện và nhận dạng nhằm cải thiện thời gian đáp ứng của hệ thống. Dữ liệu của chúng tôi được tổ chức và lưu trữ trên hệ thống tập tin phân tán HDFS (Hadoop Distributed File System) nhằm tận dụng khả năng chịu lỗi và hiệu suất truy cập cao. Các thí nghiệm cho thấy phương pháp đề xuất cải thiện đáng kể hiệu quả về mặt thời gian và độ chính xác nhận dạng khuôn mặt.

Từ khóa: Nhận dạng khuôn mặt, MapReduce, KNN, xử lý ảnh.

I. GIỚI THIỆU

An toàn, bảo mật thông tin dữ liệu luôn là mối quan tâm hàng đầu với những người sử dụng máy tính và các hệ thống xác thực thông tin. Nếu không có giải pháp bảo vệ thích hợp, khi tương tác với mạng toàn cầu thì khả năng mất quyền kiểm soát với dữ liệu của mình càng cao. Vì vậy, việc bảo mật thông tin đóng vai trò rất quan trọng trong các hệ thống xác thực. Để xác thực một người nào đó, thông thường chúng ta sử dụng thẻ từ, mật khẩu, passport,... Tuy nhiên, các phương pháp này có nguy cơ bị đánh cắp thông tin. Nhận dạng khuôn mặt được xem là một trong những phương pháp phổ biến và quan trọng trong kỹ thuật nhận dạng sinh trắc học. Nó có khả năng nhận dạng một người nào đó thông qua các đặc điểm trên khuôn mặt của họ. Các hệ thống nhận dạng khuôn mặt tự động đã được nghiên cứu rộng rãi trong những năm gần đây bởi vì vai trò của nó trong các hệ thống điều khiển truy cập vào ra, hoặc các hệ thống giám sát thời gian thực là rất quan trọng [1]. Đã có rất nhiều thành tựu quan trọng đạt được trong vấn đề nghiên cứu. Matthew Turk và các cộng sự [2] đã trình bày một hệ thống nhận dạng khuôn mặt gần như là thời gian thực bằng cách giới thiệu kỹ thuật Eigen face trong việc trích xuất đặc trưng của khuôn mặt. Chengliang Wang, Libin Lan, Yuwei Zhang and Minjie Gu [3] đã đề xuất một kỹ thuật nhận dạng khuôn mặt hiệu quả bằng cách sử dụng phương pháp phân tích thành phần chính (PCA) và máy học Support Vector Machine (SVM). Nói chung, có rất nhiều phương pháp đã được đề xuất để giải quyết bài toán nhận dạng khuôn mặt. Trong bài báo này chúng tôi đề xuất một phương pháp nhận dạng khuôn mặt bằng cách sử dụng kỹ thuật Gabor wavelet và mô hình xử lý song song MapReduce ở giai đoạn huấn luyện và nhận dạng nhằm cải thiện thời gian đáp ứng của hệ thống.

II. CÁC CÔNG VIỆC LIÊN QUAN

1. Phép biến đổi Gabor Wavelet

1.1. Tổng quan về phép biến đổi Gabor wavelet

Hàm Gabor wavelet được đề xuất lần đầu tiên bởi Dennis Gabor. Nó được sử dụng như một công cụ để dò tìm tín hiệu nhiễu.

$$\Psi(t, t_0, \omega) = e^{-\sigma(t-t_0)^2} e^{-i\omega(t-t_0)} \quad (1)$$

Sau đó, hàm Gabor wavelet được tổng quát hóa dưới dạng hai chiều bởi Daugman mà nó được sử dụng rộng rãi trong các ứng dụng xử lý hình ảnh.

Bộ lọc Gabor wavelet $\psi_{\mu\nu}$ được định nghĩa như công thức 2. Trong đó z là một điểm trong không gian hai chiều. Tham số μ và ν lần lượt là hướng và tỉ lệ của bộ lọc Gabor, σ là độ lệch chuẩn của hàm Gauss.

$$\psi_{\mu\nu}(z) = \frac{\|k_{\mu\nu}\|^2}{\sigma^2} e^{-\frac{\|k_{\mu\nu}\|^2 \|z\|^2}{2\sigma^2}} \left[e^{ik_{\mu\nu}z} - e^{-\frac{\sigma^2}{2}} \right] \quad (2)$$

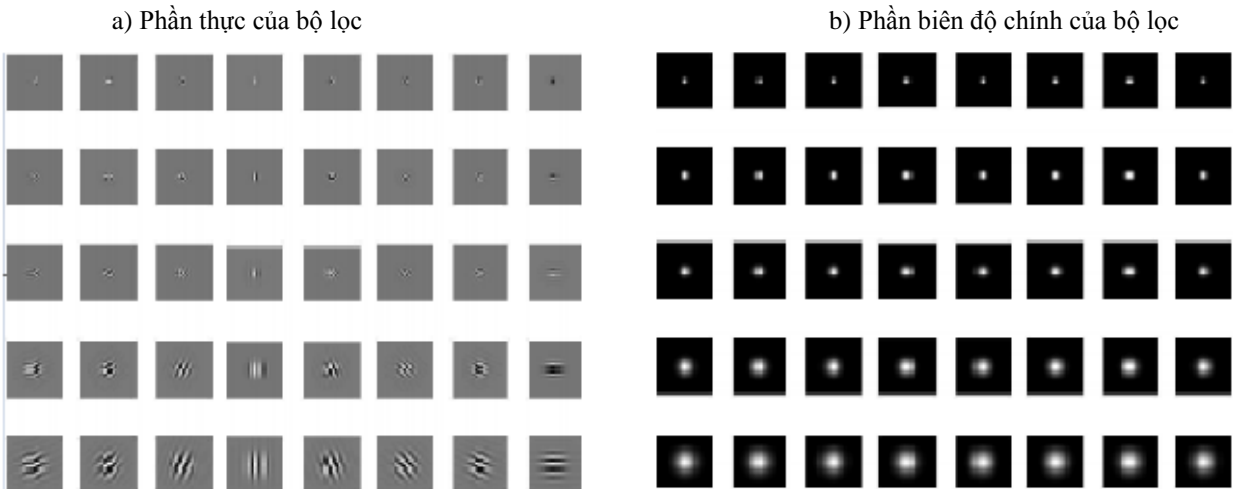
Một bộ lọc $k_{\mu\nu}$ được định nghĩa như công thức 3.

$$k_{\mu\nu} = k_{\nu} e^{i\phi_{\mu}} \tag{3}$$

Trong đó:

- $k_{\nu} = \frac{k_{\max}}{f^{\nu}}$: tần số của sóng.
- $\phi_{\mu} = \frac{\pi\mu}{8}$: hướng của sóng.
- k_{\max} : tần số cực đại của sóng.
- f^{ν} : hệ số khoảng cách giữa nhân và miền tần số.

Hình 1 biểu diễn một ví dụ minh họa cho một họ của bộ lọc Gabor với 5 scales và 8 hướng:



Hình 1. Hình minh họa một họ của Gabor wavelet với 5 tỉ lệ và 8 hướng

1.2. Biểu diễn hình ảnh sử dụng bộ lọc Gabor wavelet

Cho $I(z)$ là giá trị mức xám của điểm z . Phép chập của $I(z)$ với bộ lọc Gabor $\Psi_{\mu\nu}$ tại vị trí z được định nghĩa bởi công thức 4.

$$O_{\mu\nu}(z) = I(z) * \Psi_{\mu\nu}(z) \tag{4}$$

Giá trị của $\|O_{\mu\nu}(z)\|$ là một đặc trưng của bộ lọc Gabor tại vị trí z với hướng μ và tỷ lệ ν một vector đặc trưng của bộ lọc Gabor đại diện cho toàn bộ ảnh đạt được bằng cách ghép theo dòng của tất cả các giá trị $\|O_{\mu\nu}(z)\|, \forall z \in \{0,1,2,3,4\}, \mu \in \{0, \dots, 7\}$. Gọi $G(I)$ là vector đặc trưng Gabor của ảnh thứ I , ta có công thức 5.


$$G I = \|\|O_{00}\|\|, \|\|O_{01}\|\|, \dots, \|\|O_{10}\|\|, \dots, \|\|O_{47}\|\| \tag{5}$$

Giả sử chúng ta có ảnh khuôn mặt đầu vào như hình 2.



Hình 2. Ảnh khuôn mặt

Sau khi áp bộ lọc Gabor lên ảnh thì phần đáp ứng về biên độ được biểu diễn như hình 3.



Hình 3. Phần biên độ của bộ lọc Gabor

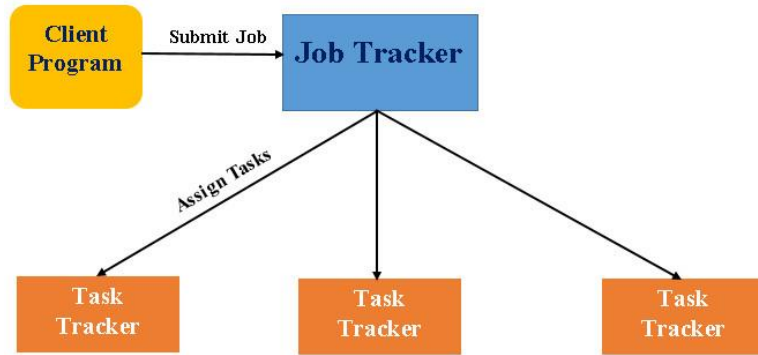
2. Spark và hệ thống tập tin phân tán HDFS (Hadoop Distributed File System)

Apache Spark được phát triển vào năm 2009 bởi AMPLab tại đại học California. Spark cung cấp mô hình thực thi cho phép tính toán trên cụm nhằm làm tăng khả năng tính toán. Bên cạnh đó, Spark hỗ trợ tính toán tại bộ nhớ trong giúp truy xuất dữ liệu nhanh hơn bộ nhớ ngoài. Trong một số kết quả thực nghiệm cho thấy Spark có thể chạy nhanh gấp 10 đến 100 lần so với Hadoop [8,9]. Spark Core trong cấu trúc các tầng của Spark là một thành phần của Spark: cung cấp những chức năng cơ bản nhất của Spark như lập lịch cho các tác vụ, quản lý bộ nhớ, phục hồi lỗi, tương tác với các hệ thống lưu trữ... Đặc biệt, Spark Core cung cấp API để định nghĩa RDD (Resilient Distributed DataSet) là tập hợp của các thành phần được phân tán trên các nút (node) của cụm (cluster) và có thể được xử lý song song. Trong nghiên cứu này, chúng tôi thực hiện các công việc rút trích đặc trưng, phân loại theo mô hình MapReduce trong môi trường Spark.

Hadoop là nền tảng hỗ trợ cho phép xử lý phân tán các tập dữ liệu lớn trên các cụm máy tính. Hadoop cung cấp hệ thống file phân tán (HDFS) và hỗ trợ mô hình MapReduce cho phép các ứng dụng làm việc với nhiều nút với hàng petabyte dữ liệu. Một cụm máy tính cài đặt hệ thống HDFS có hai loại nút: Nút tên (NameNode), hay còn gọi là nút chủ (master), và nút dữ liệu (DataNodes), hay còn gọi là nút tớ (worker). NameNode quản lý không gian tên hệ thống tập tin. Nó duy trì cây hệ thống tập tin và siêu dữ liệu cho tất cả các tập tin và thư mục trong cây. NameNode nhận biết các DataNode mà trên đó tất cả các khối cho một tập tin được đặt phân tán. Các DataNode lưu trữ và lấy khối khi nó được gọi (bởi người dùng hoặc từ nút chủ).

3. Mô hình MapReduce

MapReduce là một trong những thành phần chính của Hadoop, đây là mô hình lập trình có khả năng mở rộng một cách tuyến tính. Nó thực thi dựa trên một cụm các máy tính gọi là cluster, công việc thực thi sẽ được chia thành hai giai đoạn: giai đoạn Map và giai đoạn Reduce. Hình 2 biểu diễn mô hình xử lý song song và phân tán MapReduce. Trong giai đoạn Map, dữ liệu đầu vào được chia thành các thành phần nhỏ, và các thành phần này sẽ được xử lý song song và phân tán bởi các tiến trình Map. Mỗi phần sẽ được xử lý bởi một tiến trình Map. Một khi dữ liệu được xử lý, đầu ra của nó sẽ là các cặp {khóa, giá trị}, dữ liệu này sau đó sẽ được chuyển cho tiến trình Reduce. Hadoop sắp xếp đầu ra của tiến trình Map theo khóa. Mỗi tiến trình Reduce nhận danh sách các giá trị liên quan đến khóa, đầu ra sẽ được lưu vào hệ thống lưu trữ file phân tán của Hadoop. Tiến trình Reduce sẽ không thể bắt đầu cho tới khi tiến trình Map hoàn thành.

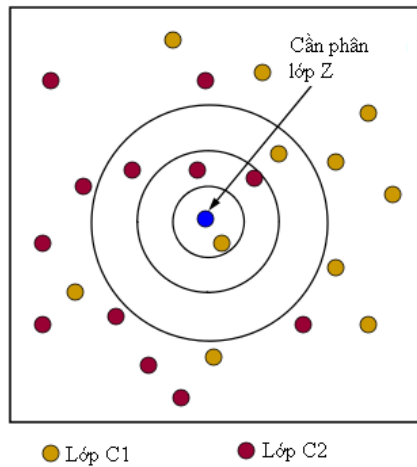


Hình 2. Mô hình MapReduce

4. Phương pháp máy học K - láng giềng gần nhất (KNN)

K - láng giềng gần nhất là phương pháp được sử dụng để phân lớp dữ liệu. Nó là thuật toán học có giám sát, kết quả của truy vấn được phân lớp dựa trên luật số đông. Thuật toán K-láng giềng gần nhất được sử dụng để phân lớp các đối tượng mới dựa trên các thuộc tính và các mẫu huấn luyện. Việc phân lớp không sử dụng bất kỳ mô hình hiệu chỉnh nào. Với một truy vấn, chúng ta tìm K đối tượng (hay điểm huấn luyện) gần nhất để thực hiện truy vấn. Sau đây là ý tưởng của phương pháp máy học dựa trên K- láng giềng gần nhất:

- Đối với một tập hợp các mẫu huấn luyện: Lưu lại tất cả các mẫu huấn luyện và xây dựng một mô hình phân lớp như được biểu diễn trong hình 3.



Hình 3. Phân lớp với K-láng giềng gần nhất

- Đối với mẫu cần phân lớp / dự đoán: xem xét mối quan hệ giữa mẫu đó với các mẫu huấn luyện để gán giá trị cho hàm mục tiêu (nhãn hoặc một giá trị số).

Phương pháp này làm việc tốt đối với việc phân lớp đa lớp và khả năng chịu nhiễu cao, quá trình huấn luyện có chi phí thấp. Tuy nhiên, chúng ta phải chọn giá trị tham số K và hàm độ đo tương đồng phù hợp giữa các mẫu. Ngoài ra, nó có thể sẽ phân lớp sai với các thuộc tính không liên quan.

Các phương pháp tính khoảng cách hoặc độ tương tự khi sử dụng KNN:

* Khoảng cách city block

Khoảng cách city block cũng được biết đến với các tên gọi khác như: khoảng cách Manhattan, khoảng cách Boxcar. Công thức xác định khoảng cách của hai điểm $\mathbf{p} = (p_1, p_2, \dots, p_n)$ và $\mathbf{q} = (q_1, q_2, \dots, q_n)$ được xác định như sau:

$$d(p, q) = d(q, p) = \sum_{i=1}^n |p_i - q_i|$$

* Khoảng cách Euclide

Giả sử $\mathbf{p} = (p_1, p_2, \dots, p_n)$ và $\mathbf{q} = (q_1, q_2, \dots, q_n)$ là hai điểm trong không gian n chiều, khi đó khoảng cách từ p đến q được tính toán theo công thức sau:

$$d(p, q) = d(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2}$$

* **Độ đo tương tự Cosine**

Độ đo cosine được sử dụng để tính toán sự tương tự giữa các vector. Cho hai vector A và B độ đo tương tự của hai vector được tính toán theo công thức sau:

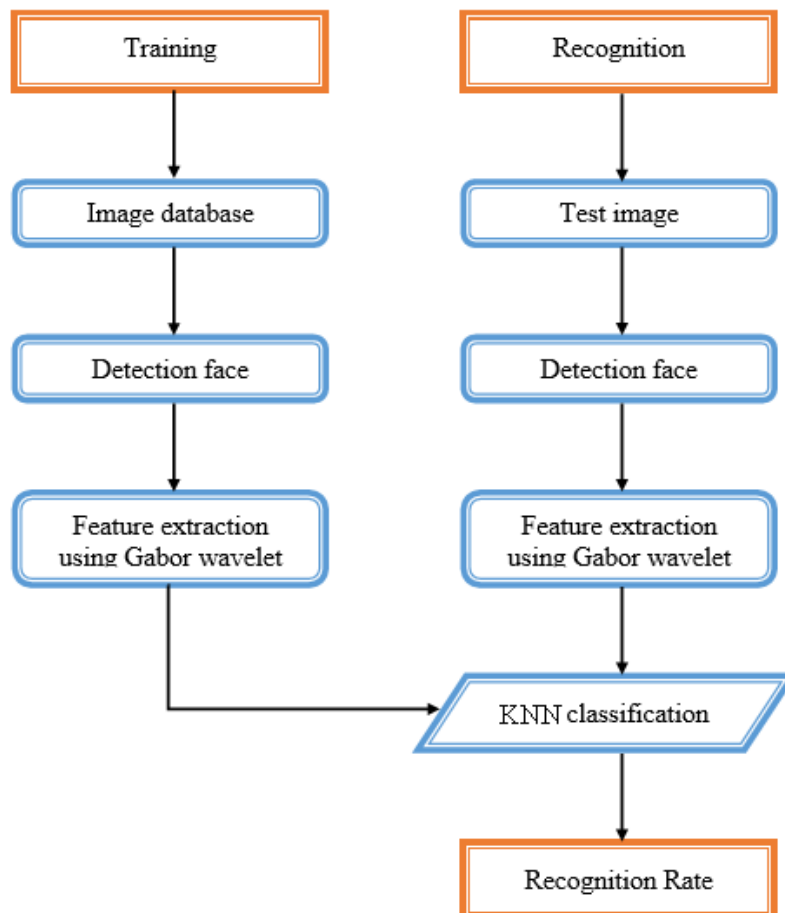
$$\text{similarity}(A, B) = \cos(\theta) = \frac{\sum_{i=1}^n A_i \times B_i}{\sqrt{\sum_{i=1}^n A_i^2 \times \sum_{i=1}^n B_i^2}}$$

Trong đó A_i, B_i lần lượt là các phần tử của vector A, B tương ứng.

III. PHƯƠNG PHÁP NHẬN DẠNG KHUÔN MẶT ĐỀ XUẤT

Trong bài báo này, chúng tôi xây dựng một hệ thống nhận dạng khuôn mặt sử dụng phép biến đổi Gabor wavelet và mô hình tính toán song song MapReduce. Phương pháp đề xuất gồm hai giai đoạn huấn luyện và nhận dạng được biểu diễn trong hình 4. Đầu tiên ở giai đoạn huấn luyện, chúng tôi sử dụng bộ lọc Gabor để trích xuất đặc trưng của khuôn mặt. Dữ liệu đặc trưng được trích xuất lưu trữ trên hệ thống tập tin phân tán HDFS. Ở giai đoạn nhận dạng, chúng tôi sử dụng giải thuật K-láng giềng gần nhất để dự đoán nhãn và đưa ra kết quả nhận dạng. Quá trình này được thực hiện theo cơ chế MapReduce nhằm cải thiện tốc độ tính toán.

Vấn đề cơ bản của nhận dạng khuôn mặt đó là việc sử dụng bộ lọc Gabor để trích xuất các điểm đặc trưng. Thay vì sử dụng lược đồ các điểm đặc trưng trên khuôn mặt, các điểm năng lượng cao sẽ được sử dụng để so sánh các khuôn mặt, điều này không chỉ giúp giảm khối lượng tính toán mà còn tăng độ chính xác của giải thuật do không cần nhận dạng các điểm đặc trưng thủ công.

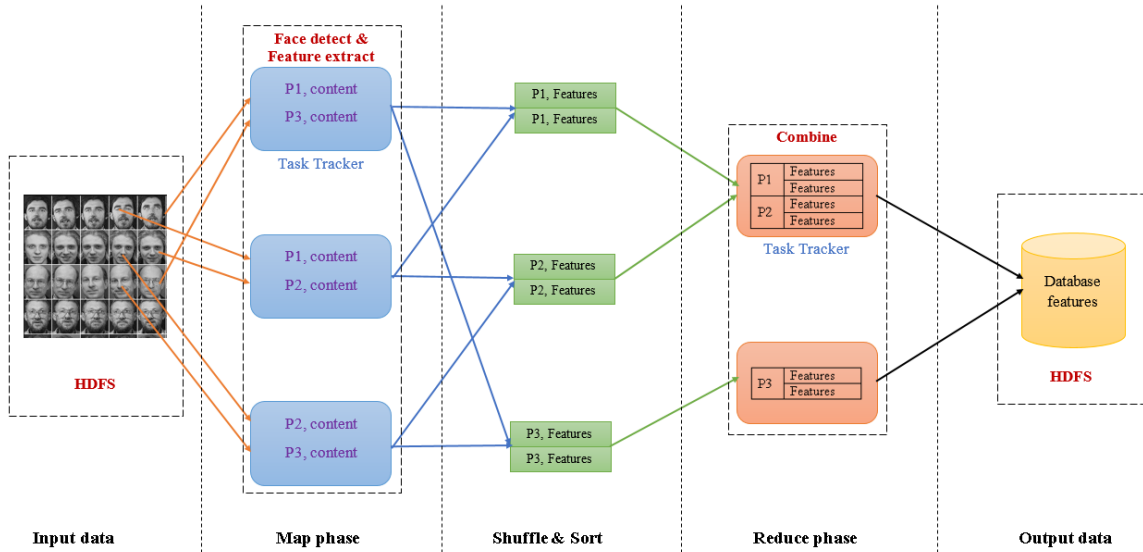


Hình 4. Mô hình hệ thống nhận dạng khuôn mặt

3.1. Giai đoạn huấn luyện

Ở giai đoạn huấn luyện, từ tập hợp các ảnh huấn luyện, chúng tôi thực hiện trích xuất đặc trưng của khuôn mặt và lưu trữ vào cơ sở dữ liệu bằng phép biến đổi Gabor wavelet. Giải thuật trích xuất đặc trưng gồm 2 bước chính (Hình 5):

- Bước 1: Xác định vector đặc trưng bằng phép biến đổi Gabor wavelet.
- Bước 2: Lưu trữ vector đặc trưng trên hệ thống tập tin HDFS

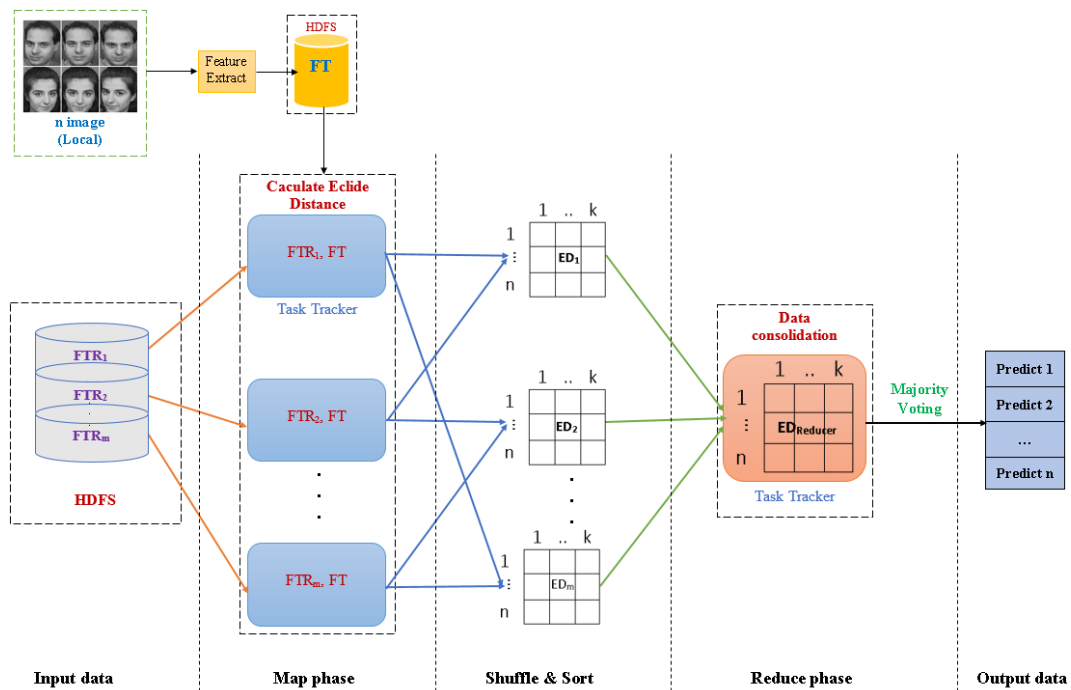


Hình 5. Mô hình huấn luyện ảnh với MapReduce

Quá trình huấn luyện ảnh khuôn mặt được thực hiện như hình 5. Từ tập hợp các ảnh đầu vào, chúng được chia thành các tập ảnh con và sẽ trích xuất đặc trưng của mỗi ảnh theo cơ chế MapReduce. Mỗi ảnh sẽ được trích xuất đặc trưng bởi một tiến trình Map. Dữ liệu đầu ra của tiến trình Map là các vector đặc trưng ảnh. Sau đó, ở tiến trình Reduce, các vector đặc trưng này được sắp xếp và tập hợp lại tạo thành các vector đặc trưng của mỗi ảnh khuôn mặt đồng thời được lưu trữ vào hệ thống tập tin phân tán HDFS.

3.2. Giai đoạn nhận dạng

Từ cơ sở dữ liệu của các vector đặc trưng của ảnh huấn luyện, chúng tôi thực hiện việc nhận dạng bằng phương pháp máy học K-láng giềng gần nhất. Ý tưởng chính là trích xuất đặc trưng của ảnh cần nhận dạng và sau đó sử dụng mô hình K-láng giềng gần nhất để phân lớp.



Hình 6. Mô đun nhận dạng ảnh

Quá trình huấn luyện ảnh được minh họa như hình 6. Từ cơ sở dữ liệu chứa các đặc trưng của ảnh huấn luyện và đặc trưng của ảnh kiểm tra, chúng tôi thực hiện Map vector đặc trưng của ảnh cần kiểm tra nhận dạng vào cơ sở dữ liệu chứa các vector đặc trưng đã huấn luyện. Kết quả của giai đoạn này sẽ là đầu vào của tiến trình Reduce. Giai đoạn Reduce sẽ sắp xếp các vector đặc trưng và kết hợp chúng lại với nhau dựa trên nhãn khóa để cập nhật lại giá trị mới tương ứng khóa này. Dựa trên phương pháp KNN, hệ thống đưa ra quyết định nhãn gần nhất với ảnh kiểm tra và hiển thị kết quả nhận dạng khuôn mặt.

IV. KẾT QUẢ NGHIÊN CỨU

Trong bài báo này chúng tôi tiến hành thực nghiệm hệ thống trên hai tập cơ sở dữ liệu ảnh khuôn mặt AT&T (của AT&T Laboratories Cambridge) và Yale (của UCSD Computer Vision). Cơ sở dữ liệu ảnh AT&T gồm có 40 đối tượng, mỗi đối tượng có 10 ảnh khuôn mặt trạng thái khác nhau. Ảnh được chụp và thời gian khác nhau, có sự thay đổi ánh sáng, biểu cảm của khuôn mặt (mở mắt, nhắm mắt, cười, ngạc nhiên,...). Kích thước ảnh là 92 x 112 pixel. Tất cả ảnh được chụp ngược sáng, nền ảnh đồng nhất. Cơ sở dữ liệu ảnh Yale: gồm 165 ảnh xám định dạng GIF của 15 đối tượng, mỗi đối tượng có 11 ảnh khuôn mặt. Các ảnh được chụp với các trạng thái và đặc điểm khác nhau: cười, vui vẻ, có kính, không kính, nháy mắt,... Kích thước ảnh là 20x243 pixel. Quá trình nhận dạng khuôn mặt được thực hiện như mô tả ở giai đoạn nhận dạng (hình 6). Chúng tôi chọn số ảnh huấn luyện và kiểm tra theo tỷ lệ 3:1. Số node sử dụng là 3, trong đó 1 node cho master quản lý tiến trình và 2 node cho slaver thực thi rút trích đặc trưng và nhận dạng. Sau đây là kết quả thực nghiệm với độ chính xác được trình bày trong Bảng 1 và thời gian thực hiện biểu diễn trong Bảng 2.

Để đánh giá so sánh về độ chính xác chúng tôi sử dụng 2 phương pháp đó là Eigenfaces và Gabor wavelet.

Bảng 1. Độ chính xác nhận dạng khi sử dụng phương pháp Eigenfaces kết hợp với KNN

Tập dữ liệu	Tỷ lệ Eigenvector được giữ lại	Cách tính khoảng cách	
		City block	Euclidean
AT&T	5%	78.33	79.16
	10%	85.00	82.50
	20%	87.50	83.33
	30%	86.66	84.16
	40%	86.66	83.33
	50%	85.83	84.16
Yale	5%	61.66	63.33
	10%	73.33	71.66
	20%	80.00	73.33
	30%	78.33	73.33
	40%	80.00	75.00
	50%	80.00	76.66
	60%	80.00	76.66

Nhìn vào kết quả của bảng 1 ta thấy rằng, khi sử dụng phương pháp tính khoảng cách city block trong KNN để nhận dạng khuôn mặt thì tỷ lệ Eigenvector tối ưu được giữ lại để tạo cơ sở dữ liệu nhận dạng ảnh là khoảng 20%. Bởi vì khi tăng số lượng Eigenvector lên thì tỷ lệ nhận dạng không tăng mà còn giảm, lý do là khi tăng số lượng Eigenvector thì cũng chính là tăng số lượng thông tin trên ảnh cần giữ lại. Việc giữ lại quá nhiều thông tin như vậy có thể sẽ kèm theo các thông tin nhiễu nên sẽ làm ảnh hưởng đến kết quả nhận dạng. Đối với phương pháp tính khoảng cách Euclidean trong KNN ta thấy rằng không thích hợp với bài toán nhận dạng khuôn mặt theo phương pháp Eigenfaces vì tỷ lệ nhận dạng không cao. Ở bảng 1 cũng cho thấy thấy rằng kết quả nhận dạng của tập dữ liệu AT&T cao hơn Yale. Lý do là giữa các ảnh khuôn mặt trong tập dữ liệu Yale có sự biến đổi rất lớn về ánh sáng, biểu cảm, phỏng nền,... so với các ảnh trong cơ sở dữ liệu AT&T.

Nhìn vào bảng 2 ta thấy rằng kích thước cửa sổ chấp tối ưu là khoảng 10 x 10. Tham số này rất quan trọng trong việc trích đặc trưng ảnh. Chúng ta cần chọn kích thước cửa sổ đủ nhỏ để thu được những đặc điểm quan trọng và đủ lớn để tránh phần dư thừa. Trong nghiên cứu này, chúng tôi sử dụng độ đo tương tự correlation hoặc cosine đều cho kết quả nhận dạng tương đối giống nhau. Bảng 2 cũng cho ta thấy rằng khi thực hiện nhận dạng khuôn mặt sử dụng kỹ thuật Gabor wavelet thì kết quả nhận dạng tương đối cao và ít bị ảnh hưởng bởi nhiễu thông tin (cả 2 tập dữ liệu đều cho kết quả nhận dạng tương đương nhau trong khi hai cơ sở dữ liệu có sự khác biệt rất lớn giữa các ảnh như: biểu cảm, độ chiếu sáng, phỏng nền,...).

Bảng 2. Độ chính xác nhận dạng khi sử dụng phương pháp Gabor wavelet kết hợp với KNN

Tập dữ liệu	Kích thước cửa sổ chấp	Cách tính khoảng cách		
		Correlation	Cosine	Euclide
AT&T	7 x 7	81.67	80.83	48.33
	8 x 8	81.67	81.67	53.33
	9 x 9	81.67	80.83	53.33
	10 x 10	90.50	91.00	48.33
	11 x 11	85.00	84.17	50.00
	12 x 12	83.33	83.33	50.83
	13 x 13	84.17	84.17	52.50
Yale	7 x 7	83.33	88.33	50.00
	8 x 8	86.67	80.00	55.00
	9 x 9	86.67	86.67	55.00
	10 x 10	92.30	92.00	58.33
	11 x 11	81.67	83.33	51.67
	12 x 12	80.00	80.00	58.33
	13 x 13	83.33	83.33	55.00

Bảng 3. Thời gian thực hiện

Tập dữ liệu	Phương pháp thực hiện	Thời gian thực hiện (giây)
AT&T	Cục bộ	163
	MapReduce	60
Yale	Cục bộ	253
	MapReduce	120

Từ kết quả thực nghiệm ta thấy: Độ chính xác của phương pháp đề xuất là như nhau với tập dữ liệu huấn luyện được lưu trữ cục bộ trên một máy tính và được lưu trữ trên hệ thống tập tin phân tán HDFS với 3 node thực nghiệm sử dụng mô hình MapReduce. Tuy nhiên, nếu tập dữ liệu được lưu trữ trên hệ thống tập tin phân tán HDFS và phương pháp đề xuất sử dụng mô hình MapReduce thì thời gian tính toán được cải thiện nhanh hơn so với phương pháp không sử dụng mô hình MapReduce.

V. KẾT LUẬN

Nhận dạng khuôn mặt là một lĩnh vực hấp dẫn đối với việc nghiên cứu trên máy tính. Các hệ thống xác thực hiện nay như: điện thoại thông minh, rút tiền tự động, chấm công,... đang ngày càng gia tăng ứng dụng nhận dạng khuôn mặt nhằm đảm bảo tính an toàn và bảo mật thông tin. Bên cạnh đó, con người có khả năng nhận ra một khuôn mặt quen thuộc một cách dễ dàng. Tuy nhiên, khả năng nhớ của con người là có giới hạn. Việc nghiên cứu mô phỏng khả năng nhận dạng của bộ não con người đối với việc nhận dạng khuôn mặt dựa trên máy tính là rất cần thiết. Trong bài báo này chúng tôi đã xây dựng một hệ thống nhận dạng khuôn mặt sử dụng bộ lọc Gabor để rút trích đặc trưng và KNN để thực hiện nhận dạng khuôn mặt. Quá trình thực hiện trích xuất đặc trưng và nhận dạng được thực hiện với mô hình MapReduce. Độ chính xác nhận dạng trung bình là 91%. Phương pháp đề xuất cải tiến hiệu quả về mặt thời gian tính toán đồng thời giải quyết hiệu quả bài toán về khả năng hạn chế về tài nguyên của máy tính như bộ nhớ, khả năng xử lý, phù hợp cho các hệ thống làm việc trong môi trường dữ liệu lớn.

TÀI LIỆU THAM KHẢO

- [1] Anil K. Jain, Brendan Klare and Unsang Park, Face Recognition: Some Challenges in Forensics, in IEEE International Conference Automatic Face & Gesture Recognition and Workshops (FG 2011), 2011, pp. 726-733.
- [2] M. A. Turk and A. P. Pentland, Face recognition using eigenfaces, In IEEE Conference on Computer Vision and Pattern Recognition, Hawaii, 1991, pp.586-591.
- [3] Chengliang Wang, Libin Lan, Yuwei Zhang and Minjie Gu, Face Recognition Based on Principle Component Analysis and Support Vector Machine, In IEEE Conference Intelligent Systems and Applications (ISA), 2011, pp.1-4.
- [4] S. P. Natarajan C. MageshKumar, R. Thiyagarajan and S. Arulselvi, Gabor features and Ida based face recognition with ann classier, Master's thesis, In International Conference Emerging Trends in Electrical and Computer Technology (ICETECT), 2011.

- [5] Kais Loukil, Faten Bellakhdhar and Mohamed ABID. Face recognition approach using gabor wavelets, pca and svm. Master's thesis, International Journal of Computer Science Issues, Vol. 10, Issue 2, No 3, 2013.
- [6] Prajesh P Anchalia, Kaushik Roy, The k-Nearest Neighbor Algorithm Using MapReduce Paradigm, 2014 Fifth International Conference on Intelligent Systems, Modelling and Simulation, 2014.
- [7] Jesús Mailló, Isaac Triguero, Francisco Herrera, A MapReduce-based k-Nearest Neighbor Approach for Big Data Classification, IEEE Trustcom/BigDataSE/ISPA, 2015.
- [8] M. C. M. J. F. S. S. a. I. S. Matei Zaharia, Spark: cluster computing with working sets, Proceedings of the 2Nd USENIX Conference on Hot Topics in Cloud Computing, p. 10, 2010.
- [9] A. P. a. M. S. Ranjani, Spark–An Efficient Framework for Large Scale Data Analytics, International Journal of Scientific & Engineering Research, vol. 7, 2016.

FACIAL RECOGNITION USING PARALLEL PROCESSING AND DISTRIBUTED MODEL BY MAPREDUCE

Phan Anh Cang , Le Hoang Son, Phan Thuong Cang

ABSTRACT: Facial recognition methods are widely used and offer significant benefits to users in authentication, security and crime monitoring systems. In addition to accuracy, traditional face recognition methods face the problems of time-consuming to identify, large computing power, and application to distributed systems with large data environment aiming at efficient data processing and analysis. To solve these problems, we proposed a facial feature extraction method using the Gabor wavelet technique and the MapReduce parallel processing model at the stage of the training and identification. Our data is organized and stored on Hadoop Distributed File System (HDFS) to take advantages of fault tolerance and high access performance. Experiments show that the proposed method significantly improves the time efficiency and facial recognition accuracy.

Keywords: Facial recognition, MapReduce, KNN, Image Processing.