

지지벡터기계와 적응적 특징을 이용한 강인한 지문분류

(A Robust Fingerprint Classification using SVMs with Adaptive Features)

민준기[†] 조성배^{**}
(Jun-Ki Min) (Sung-Bae Cho)

요약 지문분류는 지문을 전역특징에 따라 미리 정의된 클래스로 분류하여 대규모 지문식별시스템의 매칭시간을 감소시키는데 유용하다. 그런데, 지문의 고유성으로 인해 전역특징이 다양하게 분포함에도 불구하고, 기존의 지문분류 방법들은 모든 지문에 대해 고정된 영역으로부터 비적응적으로 전역특징을 추출하였다. 본 논문에서는 다양한 지문을 효과적으로 분류하기 위해 각 지문에 적응적으로 특징을 추출하는 방법을 제안한다. 이는 각 지문의 용선 방향의 변화량을 계산하여 적응적으로 특징영역을 탐색한 후, 특징영역내의 용선 방향 값을 특징벡터로 추출하고 지지벡터기계(Support Vector Machines)를 이용해 분류한다. 본 논문에서는 NIST4 데이터베이스를 이용하여 실험을 수행하였다. 그 결과 5클래스 분류에 대해 90.3%, 4클래스 분류에 대해 93.7%의 분류성능을 얻었으며, 비적응적으로 추출한 특징벡터와의 비교실험을 통해 제안하는 적응적 특징추출방법의 유용성을 입증하였다.

키워드 : 지문분류, 적응적 특징추출, 용선 방향 변화량, 지지벡터기계

Abstract Fingerprint classification is useful to reduce the matching time of a huge fingerprint identification system by categorizing fingerprints into predefined classes according to their global features. Although global features are distributed diversly because of the uniqueness of a fingerprint, previous fingerprint classification methods extract global features non-adaptively from the fixed region for every fingerprint. We propose an novel method that extracts features adaptively for each fingerprint in order to classify various fingerprints effectively. It extracts ridge directional values as feature vectors from the region after searching the feature region by calculating variations of ridge directions, and classifies them using support vector machines. Experimental results with NIST4 database show that we have achieved a classification accuracy of 90.3% for the five-class problem and 93.7% for the four-class problem, and proved the validity of the proposed adaptive method by comparison with non-adaptively extracted feature vectors.

Key words : Fingerprint classification, Adaptive feature extraction, Variations of ridge directions, Support vector machines

· 이 연구는 한국과학재단(KOSEF)을 통해 생체인식연구센터(BERC)에서 지원받았음

† 학생회원 : 연세대학교 컴퓨터과학과
loomlike@sclab.yonsei.ac.kr
** 종신회원 : 연세대학교 컴퓨터과학과 교수
sbcho@cs.yonsei.ac.kr

논문접수 : 2007년 7월 9일
심사완료 : 2007년 11월 29일

Copyright © 2008 한국정보과학회 : 개인 목적이거나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지 : 소프트웨어 및 응용 제35권 제1호(2008.1)

1. 서론

지문은 손가락 끝 안쪽의 피부가 융기하여 형성된 융선(Ridge)들의 문형으로, 개인마다 고유하기 때문에 신속하고 안전한 신원 확인 및 인증이 가능한 생체인식 수단으로 널리 연구되고 있다[1]. 지문은 두 종류의 특징인 특징점(Minutiae)과 특이점(Singular point)을 갖는다. 특징점은 개개의 융선이 형성하는 독특한 패턴을 말하며, 융선이 끝나는 점인 끝점(Ending)과 융선이 두 갈래로 나뉘지는 부분인 분기점(Bifurcation) 등이 있다. 융선 특징점의 위치와 방향은 사람마다 고유하기 때문에 지문식별에 사용된다. 특이점은 융선들의 방향이 급




그림 1 (a) 지문의 특징과 (b) 특이점에 따라 분류한 5가지 클래스

격하게 변하는 점으로, 융선의 흐르는 모양에 따라 원 모양을 이루는 점인 중심점(Core)과 세 방향으로 뻗어 나가는 점인 삼각주(Delta)로 구분된다. 이들의 개수와 위치는 지문을 분류하는 기준으로 사용되는데, 그림 1 (a)는 지문의 특징을 나타낸다.

지문분류는 미리 정의된 카테고리 지문을 분류하여 매칭단계의 비교대상을 줄여주는 것으로, 대규모 지문식별시스템에서 검색시간을 단축시키는데 유용하다. 실제 미국의 FBI 등에서는 범죄수사에 이용하기 위하여 지문을 8가지 이상으로 분류하며, 연구 분야에서는 그림 1 (b)와 같이 주로 Whorl, Right loop, Left loop, Arch, Tented arch의 5가지 클래스로 분류한다. Whorl은 2개의 삼각주가 존재하는 클래스로, 중심점의 개수에 따라 Whorl과 Double loop로 분리하기도 한다. 삼각주가 하나일 경우, 중심점이 삼각주의 오른쪽에 위치하면 Right loop 클래스, 왼쪽에 위치하면 Left loop 클래스, 수직위에 위치하면 Tented arch 클래스가 된다. 특이점이 존재하지 않는 경우에는 Arch 클래스로 분류한다.

지문 자동분류 시스템은 지문영상으로부터 분류특징을 추출하고, 이를 휴리스틱한 규칙이나 패턴인식기술 등을 사용하여 분류한다. 이때 분류특징으로 특이점만을 사용하는 방법은 잡음에 취약하며, 따라서 지문 영상으로부터 고정된 크기의 특징영역(혹은 관심영역; Region of Interest, ROI)을 선택하고 이에 필터를 적용한 변환 영상 정보나 융선의 구조적 정보 등을 이용하는 방법이 주로 사용되어왔다[1]. 하지만 지문은 고유성으로 인하여 동일한 클래스 내에도 다양한 모양을 띄고 특징영역의 크기와 위치도 서로 다르기 때문에 획일적인 크기의 특징영역으로는 분류특징을 모두 포함하지 못하거나 특징정보가 없는 영역을 포함하게 된다. 그림 2는 클래스 내 다양성을 보여주는 예로, 모두 Right loop 클래스에 속하지만 서로 다른 크기의 특징영역을 갖는 것을 확인할 수 있다.




그림 2 다양한 크기의 특징영역을 갖는 지문들 (□: 특징영역)

본 논문에서는 지문의 클래스 내 다양성을 해결하여 분류성능을 높이기 위해 지문에 따라 적용적으로 특징영역의 크기를 결정하고, 선택된 특징영역의 융선정보를 4방향과의 차로 정규화하여 특징벡터로 사용하는 방법을 제안한다. 이는 지문의 특이점들이 다양하게 분포하더라도 융선 방향성 변화량에 따라 특징영역의 위치와 크기를 선택하기 때문에 각 지문의 고유한 특징영역을 정확하게 탐색할 수 있다. 적응적 특징영역이 선택되면 고정된 길이의 특징벡터를 추출하기 위하여 영역을 8×8 블록으로 나누고, 각 블록의 방향성 값과 4방향과의 차를 특징 값으로 사용한다. 분류단계에서는 지문분류를 포함한 다양한 패턴인식분야에서 높은 성능을 보이는 지지벡터기계(Support vector machines, SVM)을 사용하였다. 본 논문에서는 지문분류 연구에서 널리 사용되는 NIST4 데이터베이스의 지문영상을 이용한 분류실험을 수행하였으며, 기존 방식인 고정된 크기의 특징영역으로부터 추출한 비적용적 특징벡터와의 비교분석을 통해 제안하는 방법의 유용성을 검증하였다.

본 논문의 나머지 부분은 다음과 같이 구성되어 있다. 2장은 배경연구로 기존의 지문분류방법들과 SVM 분류기에 대해 소개한다. 3장에서는 제안하는 방법인 적응적 특징추출방법에 대해 자세히 설명한 후, 4장에서 방법의 유용성을 입증하기 위한 실험 과정과 결과를 보여준다. 마지막으로 5장에서 논문의 결론과 향후연구에 대해 언급한다.

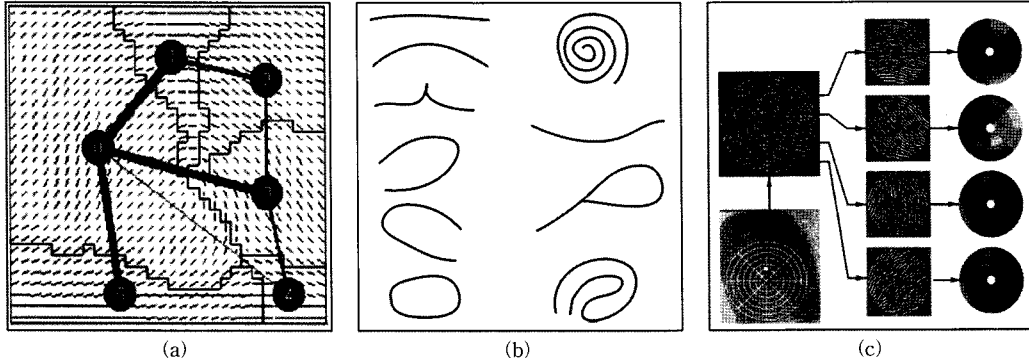


그림 3 기존에 연구된 지문특징 예. (a) Cappelli[3], (b) Chang[4], (c) Jain[5].

2. 배경연구

2.1 기존의 지문분류방법

지문분류를 위한 다양한 특징추출방법들이 연구되고 있으며, 크게 특이점(Singularities)기반 방법, 구조특징(Structural features)기반 방법, 그리고 주파수(Frequency)기반 방법으로 나눌 수 있다. 본 장에서는 NIST4 데이터베이스 지문을 5클래스로 분류한 연구들에 대해 각 방법별로 간략히 소개한다.

특이점기반 방법은 특이점인 중심점과 삼각주를 지문 영상으로부터 직접 추출한 뒤, 이를 이용하여 지문을 분류한다. 특이점추출 알고리즘으로는 용선 방향성의 커브를 이용하는 Poincare가 널리 이용되며, Karu는 이를 이용하여 추출한 특이점의 개수와 위치를 휴리스틱 규칙을 통해 분류하여 85.4%의 성능을 얻었다[2]. 이 방법은 간단하고 직관적이지만 특이점 정보에 의존적이기 때문에 영상의 품질이 좋지 않은 경우 분류가 어렵다는 단점이 있다.

구조특징기반 방법은 학습데이터를 이용하여 클래스를 대표하는 구조모델을 생성한 뒤, 새로 입력된 샘플의 구조모델과의 유사도 비교를 통해 지문을 분류하는 방법이다. Capelli[3]는 지문을 용선 방향이 동일한 영역들로 나뉘 이들 간의 관계를 그림 3(a)와 같이 그래프로 모델링하였으며, 이를 통해 87.1%의 분류성능을 보였다. 이 방법은 각 클래스를 하나의 템플릿으로 모델링하기 때문에 전형적인 클래스 특징을 갖지 않는 지문은 분류하기 어렵다. 용선의 전체적인 흐름모양을 구조적으로 나타낸 것과는 대조적으로 Chang[4]은 용선의 개별적 모양을 구조적으로 모델링 하였다(그림 3(b)). 그는 용선 커브모양을 추출하고, 각 클래스를 이들의 패턴조합으로 나타내는 방법을 통해 94.8%의 분류성능을 획득했다. 하지만 이 방법 역시 잡음에 민감하기 때문에 특징 추출 단계에서 5.1%의 거부율이 적용되었다.

주파수기반 방법은 Fourier변환식이나 Gabor필터 등을 이용하여 지문영상을 변형하고, 미리 결정한 특징영역으로부터 영상의 음영 값이나 분산 등을 계산하여 특징벡터를 추출한다. Jain[5]은 방향성이 다른 4개의 Gabor필터를 적용하여 원형의 특징영역으로부터 특징벡터를 추출하였으며, 추출한 분류기의 2단계 결합모델을 통해 90.0%의 분류성능을 보였다(그림 3(c)). 이 방법은 특징영역이 지문영상을 벗어나는 경우가 있어서 1.8%의 거부율이 적용되었다. 이밖에도 하나 이상의 특징추출방법을 혼용하는 방법들이 연구되고 있으며[6], 분류알고리즘의 개선을 통해 분류성능을 높이려는 연구도 진행 중이다[7].

2.2 지지벡터기계

SVM은 비선형 매핑함수를 이용하여 학습 데이터의 샘플 공간을 선형 초평면(Hyperplane)이 만들어지는 고차원 특징 공간으로 매핑하고, 인식오류를 최소화하는 최적 초평면을 찾는다. 이 때 초평면과 가장 가까운 입력샘플벡터를 지지벡터(Support vector)라 한다.

n 개의 학습데이터 중에서 i 번째 샘플($i=1, \dots, n$)인 x_i 의 클래스 레이블을 $c_i \in \{1, -1\}$ 라고 할 때, 최적 초평면에 대한 결정 함수의 식은 다음과 같다.

$$f(x) = \sum_{i=1}^n \alpha_i c_i K(x, x_i) + b, \quad K(x, x_i) = \Phi(x) \cdot \Phi(x_i) \quad (1)$$

식 (1)에서 b 는 상수이고, 계수 α_i 는 x_i 가 지지벡터인 경우에만 0이 아닌 값을 갖는다. 커널(Kernel)함수 $K(x, x_i)$ 는 비선형 매핑함수의 내적계산을 함수 형식으로 치환하여 간단하게 해준다. 대표적 커널함수로는 다항(Polynomial)함수(식 (2))와 가우시안(Gaussian)함수(식 (3))가 있다.

$$K(x, x_i) = (1 - x \cdot x_i)^d \quad (2)$$

식 (2)의 파라미터 d 는 다항함수의 차수이고, 식 (3)의 σ 는 가우시안의 분산을 나타낸다.

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (3)$$

SVM은 본래 이진분류기이기 때문에 지문과 같은 다중 클래스를 분류하기 위해서는 여러 SVM을 One-vs-rest나 Pairwise등의 전략을 이용하여 조합하여야 한다 [7]. One-vs-rest는 한 클래스와 나머지 클래스를 분류하는 SVM을 생성하는 전략이다. 이는 샘플의 클래스 레이블을 특정 클래스($c=1$)와 그 외의 클래스($c=-1$)로 이진화하여 SVM을 학습시킨다. 따라서 M 클래스 문제의 경우 M 개의 분류기를 생성한다. 평가샘플의 클래스 레이블은 M 개의 SVM중 양의 값을 출력한 SVM의 레이블이 된다. Pairwise는 다중 클래스를 두 개씩 짝지어 이진분류문제로 분해하는 전략으로, M 클래스 문제의 경우 $M_2C_2 = M(M-1)/2$ 개의 분류기를 사용하게 된다. 각 SVM은 짝지어진 두 클래스에 속하는 샘플만 사용하여 학습하기 때문에 해당 클래스 외의 샘플에 대해서는 정확한 분류결과를 출력할 수 없다. 따라서 투표 방법(Majority voting)이나 ECOC(Error Correcting Output Code) 등의 분류기 결합방법을 이용하여 모든 SVM의 출력결과를 결합하여 분류를 수행한다.

3. 적응적 특징추출

본 논문에서 제안하는 방법은 적응적 특징영역 탐색

단계와 특징벡터 추출단계로 나뉜다. 그림 4는 전체 특징추출과정을 나타내며, 그림 5는 이를 이용한 자동지문분류시스템을 보여준다.

3.1 적응적 특징영역 탐색

기존의 특이점 탐색 알고리즘은 방향성 변화량이 최대가 되는 지점을 특이점으로 판단하기 때문에 영상의 잡음으로 인하여 특징을 추출하지 못하거나 잘못 탐색하는 경우가 발생한다. 또한 중심점과 삼각주가 인접해 있거나 Arch와 같이 특이점이 없는 경우 특징추출이 어렵다는 단점이 있다[8]. 따라서 제안하는 방법에서는 특이점을 포함하는 최적의 특징영역을 적응적으로 선택하기 위해 각 지문의 용선 방향성필드를 구한 뒤 방향 변화가 많은 영역을 탐색한다.

우선 전처리과정으로 전경분리(Segmentation)를 수행한다. 이를 위해 입력영상을 $w \times w$ 화소(Pixel)의 블록으로 나누고, 블록별 음영(Gray)값의 평균과 분산을 이용한다. 지문영상에서 용선은 검은색으로 나타나기 때문에 전경부분의 블록은 배경에 비해 음영의 평균값이 작고 분산이 크다. 영상으로부터 전경영역을 찾아낸 뒤, 용선의 방향성필드를 다음과 같이 Jain[9]의 방법을 이용하여 계산한다.

- 1) 영상을 $w \times w$ 화소 블록으로 나눈다.
- 2) 소벨(Sobel)연산자를 이용하여 (u, v) 변제 화소의 기울기(Gradient)값인 $\rho_x(u, v)$ 와 $\rho_y(u, v)$ 를 계산한다.

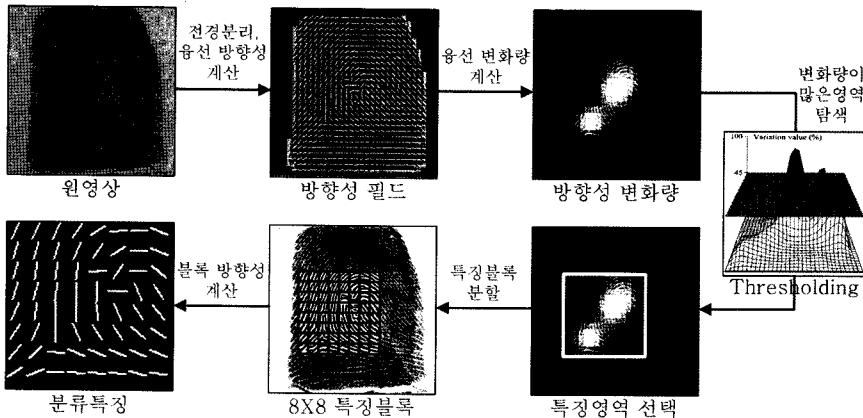


그림 4 적응적 특징추출과정




그림 5 적응적 특징추출방법을 이용한 자동지문분류시스템

3) (i, j)번째 블록의 방향성 값 $\theta(i, j)$ 를 다음 식을 이용하여 계산한다.

$$V_x(i, j) = \sum_{u=0}^{w-1} \sum_{v=0}^{w-1} 2\rho_x(iw+u, jw+v)\rho_y(iw+u, jw+v) \quad (4)$$

$$V_y(i, j) = \sum_{u=0}^{w-1} \sum_{v=0}^{w-1} (\rho_x^2(iw+u, jw+v)\rho_y^2(iw+u, jw+v)) \quad (5)$$

$$\theta(i, j) = \frac{1}{2} \tan^{-1} \left(\frac{V_y(i, j)}{V_x(i, j)} \right) \quad (6)$$

4) 영상의 잡음으로 인한 방향성 값의 오류를 줄이기 위하여 평탄화(Smoothing)를 수행한다. 우선 용선 방향성 값의 x, y성분인 Φ_x, Φ_y 를 다음과 같이 계산한다.

$$\Phi_x(i, j) = \cos(2\theta(i, j)) \quad (7)$$

$$\Phi_y(i, j) = \sin(2\theta(i, j)) \quad (8)$$

계산된 방향성분에 식 (9), (10)과 같이 $r \times r$ Lowpass 필터 F를 적용하고, 식 (11)을 이용하여 (i, j)번째 블록의 방향성값 $O(i, j)$ 를 계산한다.

$$\Phi'_x(i, j) = \sum_{k=-r/2}^{r/2} \sum_{l=-r/2}^{r/2} F(k+\frac{r}{2}, l+\frac{r}{2})\Phi_x(i+k, j+l) \quad (9)$$

$$\Phi'_y(i, j) = \sum_{k=-r/2}^{r/2} \sum_{l=-r/2}^{r/2} F(k+\frac{r}{2}, l+\frac{r}{2})\Phi_y(i+k, j+l) \quad (10)$$

$$O(i, j) = \frac{1}{2} \tan^{-1} \left(\frac{\Phi'_y(i, j)}{\Phi'_x(i, j)} \right) \quad (11)$$

본 논문에서는 전경분리와 방향성필드 계산을 위한 블록의 크기를 실험을 통해 $w=16$ 으로 설정하였다.

방향성필드를 구하고 나면, 한 블록과 주변 $n \times n$ 개의 블록 간의 방향성 변화량 $V(i, j)$ 를 다음과 같이 계산한다.

$$V(i, j) = \frac{1}{n^2} \sum_{k=-n/2}^{n/2} \sum_{l=-n/2}^{n/2} \Delta_{i,j}(k, l) \quad (12)$$

$$\Delta_{i,j}(k, l) = \begin{cases} -\delta_{i,j}(k, l) & \text{if } \delta_{i,j}(k, l) < 0 \\ \pi - \delta_{i,j}(k, l) & \text{if } \delta_{i,j}(k, l) \geq \frac{\pi}{2} \\ \delta_{i,j}(k, l) & \text{otherwise} \end{cases} \quad (13)$$

$$\delta_{i,j}(k, l) = O(i, j) - O(i+k, j+l) \quad (14)$$

이때 방향성 변화값도 방향성필드와 마찬가지로 $r \times r$ Lowpass필터 F를 이용한 평탄화를 통해 잡음을 제거한다. 방향성 변화량이 계산되면, 임계값을 $\max(V(i, j))/c$ 로 설정하고 방향성 변화값이 임계값보다 큰 블록을 선택한다. 이때, 상수 c와 방향성 변화량 계산을 위한 블록의 개수 n은 실험을 통해 각각 2.2와 5로 결정하였다. 특징영역은 그림 4와 같이 선택한 블록을 모두 포함하는 가장 작은 정사각형 영역으로 선택한다. 이 때 특징영역이 영상영역을 벗어날 경우에는 영상영역 안에 포함되도록 크기를 축소한다. 반대로 특징영역이 너무 작으면 특징추출이 어렵기 때문에 최소크기가 6×6 블록 (96×96 화소)이 되도록 하였다.

3.2 특징벡터 추출

NIST4 데이터베이스 지문영상은 품질이 좋지 않기 때문에, 본 논문에서는 특징벡터를 추출하기에 앞서 가보(Gabor)필터를 이용하여 영상개선을 수행한다. 용선의 방향과 동일한 방향의 가보필터를 적용하면 용선과 골의 차를 선명하게 해준다[5]. 영상개선은 화소단위의 필터 계산을 수행하기 때문에 많은 시간이 소요되지만, 제안하는 방법에서는 지문영역에서 선택된 특징영역만 개선하여 이를 최소화하였다.

본 논문에서는 특징영역의 용선 방향성 값을 분류특징으로 사용한다. 그림 6은 각 클래스 별로 추출된 분류특징의 예를 보여준다. 이때 방향성 값은 순환특성 ($0^\circ = 180^\circ$)을 가지고 있어서 4방향과의 차를 계산하여 특징벡터를 추출하였다. 먼저 특징영역을 그림 4와 같이 8×8 개의 블록으로 나누고 새로운 블록의 방향성필드를 3.1절의 식 (4)~(6)을 이용하여 계산한다. 특징영역의 블록 방향성필드가 구해지면(그림 4), 식 (15)와 같이 각 블록의 방향성 값 $\theta(i, j)$ 와 4방향($\gamma = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$)과의 차 $\delta_{i,j}$ 를 계산하고, 식 (16)을 이용하여 256차원 ($8 \times 8 \times 4$)의 특징벡터 $F = \{f_1, \dots, f_{256}\}$ 를 추출한다. 추출




그림 6 클래스 별 적응적 특징영역과 추출된 분류특징의 예

된 특징벡터는 패턴분류기를 통해 분류하며, 본 논문에서는 이를 위해 SVM 분류기를 이용하였다.

$$\delta_{i,j} = \theta(i, j) - \gamma \tag{15}$$

$$f_k = \begin{cases} -\delta_{i,j} & \text{if } \delta_{i,j} < 0 \\ \pi - \delta_{i,j} & \text{if } \delta_{i,j} \geq \frac{\pi}{2} \\ \delta_{i,j} & \text{otherwise} \end{cases} \tag{16}$$

4. 실험 및 결과

4.1 실험환경

제안하는 방법의 검증을 위해 지문분류 연구에서 널리 사용되는 NIST4 데이터베이스를 이용하여 실험하였다. NIST4 데이터베이스의 지문영상은 전문가에 의해 Whorl (W), Right loop (R), Left loop (L), Arch (A), Tented arch (T)의 5가지 클래스로 분류되어 있다. 각 영상은 잉크기반으로 수집된 지문을 512×480 해상도로 스캔한 것으로, 클래스마다 400개의 지문이 2회(F와 S) 등록되어 총 4,000장의 데이터베이스를 구성하고 있다. 전체 데이터 중 350쌍(17.5%)의 지문은 클래스가 모호하여 표 1과 같이 하나 이상의 클래스로 교차참조 되어 있다[10].

본 논문에서는 처음 1000쌍의 지문(F0001~F1000, S0001~S1000)은 학습데이터로, 나머지 1000쌍의 지문(F1001~S1001~S2000)은 평가데이터로 사용하였다. 교

표 1 NIST4 지문데이터의 교차참조(Cross reference) (행: 본 클래스, 열: 부 클래스)

	W	R	L	A	T
W	792	6	2	0	0
R	4	746	0	0	50
L	2	0	756	0	42
A	0	2	0	760	38
T	0	238	166	150	246

차참조 되어있는 영상에 대해서는 기존 연구와 마찬가지로 학습 시에는 첫 번째 레이블만을 이용하였고, 평가 시에는 두 가지 레이블을 모두 사용하였다[5]. 분류단계에서는 가우시안 커널 SVM의 One-vs-rest(OVR)과 Pairwise(PW) 조합전략을 이용하였다.

4.2 비적응적 방법과의 비교

본 논문에서 제안한 특징추출방법과 기존방법의 가장 큰 차이는 특징영역 선택방법에 있다. 기존의 특징추출 방법은 지문에 상관없이 고정된 크기의 특징영역을 사용하지만, 적응적 특징추출방법은 각 지문의 전역적 특징분포에 따라 적응적으로 특징영역을 선택한다. 이를 비교하기 위하여 고정된 4개의 특징영역(128×128, 192×192, 256×256, 320×320화소)으로부터 비적응적 특징벡터를 추출하였다. 비적응적 특징벡터의 추출과정은 특징영역 선택부분을 제외하고는 적응적 방법과 동일하게 하였다. 그림 7은 동일한 클래스의 두 지문(특징영역이 넓게 분포하는 지문과 좁게 분포하는 지문)에 대한 특징영역 선택결과 예를 보여준다.

좋은 분류특징은 동일한 클래스 내의 샘플들 간에는 유사한 패턴을 보이고 서로 다른 클래스의 샘플들에 대해서는 상이한 패턴을 보여 클래스를 정확히 분리할 수 있다. 본 논문에서는 제안하는 특징과 비적응적 특징들의 클래스 분리도를 평가하기 위하여 클러스터 정당성 평가척도의 하나인 Davies-Bouldin Index를 사용하였다[11]. 이는 형성된 클러스터의 정당성을 클러스터 내의 흠어짐 정도와 클러스터 간의 거리의 비율을 이용하여 분석하는 방법으로, Index값이 작을수록 클러스터들이 명확하게 분리되어 있음을 의미한다. 본 논문에서 추출한 특징들을 분석한 결과 그림 8과 같이 적응적 특징이 최소의 Index값을 보여 클래스들을 가장 정확하게 분리함을 확인하였다. 그림 9는 적응적 방법과 비적응적 방법을 이용하여 그림 2의 세 개의 지문으로부터 추출한 특징벡터의 패턴을 명암과 모양으로 나타낸 것으로,




그림 7 특징추출방법별 특징영역 선택 예




그림 8 특징벡터별 클래스 분리도. 값이 작을수록 클래스를 정확히 분리한다.

세 지문의 클래스는 모두 Right loop이기 때문에 이를 정확히 분류하기 위해서는 추출한 특징벡터의 패턴이 서로 유사해야 한다. 그림 9와 같이 실제로 적응적 특징벡터는 서로 유사한 패턴을 보였지만 비적응적 특징벡터는 서로 다른 패턴을 보였다.

앞에서 추출한 5가지 종류의 특징벡터에 대한 분류 성능을 SVM, K-NN(K-Nearest Neighbor), MLP(Multi-Layer Perceptron)분류기를 이용하여 평가하였다. MLP는 노드의 초기 가중치에 영향을 받기 때문에 10번 실험하여 평균을 계산하였다. 그림 10은 각 특징벡터에 대한 분류기별 실험결과를 보여준다. 실험결과 적응적 방법은 비적응적 특징벡터들에 비해 모든 분류기에서 높은 성능을 나타냈다. 비적응적 방법은 특징영역의 크기가 작은 경우(128x128) 주로 분류특징이 넓게 분포하는 지문들을 정확히 분류하기 어려웠으며, 반대로 특징영역의 크기가 큰 경우(320x320) 분류특징이 좁게 모여 있는 지문들을 정확하게 분류하지 못하였다. 최대 분류율은 적응적 특징벡터의 경우 OVA SVM에서 90.3%, 비적응적 특징벡터의 경우 특징영역의 크기가 192x192일 때 PW SVM에서 88.3%를 획득하였다. 표 2와 표 3은 이들의 분류결과 혼동행렬을 나타내며, 표의 행과 열은 각각 샘플의 본 클래스와 SVM을 통해 예측한 클래스를 의미한다. Tented arch(T) 클래스의 경우 비적응적




그림 10 각 분류기에 대한 특징벡터별 분류성능

표 2 적응적 특징벡터의 OVA SVM 분류결과 혼동행렬

	W	R	L	A	T
W	366	19	9	2	2
R	3	346	4	15	28
L	4	1	368	9	15
A	2	0	1	411	29
T	1	6	5	40	314

표 3 비적응적 특징벡터(192x192)의 PW SVM 분류결과 혼동행렬

	W	R	L	A	T
W	358	18	18	2	2
R	4	345	6	9	32
L	3	3	355	7	19
A	6	0	4	389	45
T	2	9	2	44	318

방법이 적응적 방법에 비해 더 많은 샘플들을 해당 클래스로 분류하였지만 이는 교차참조된 샘플로 인한 결과로, 실제 혼동행렬의 각 행의 합은 동일하지 않을 수 있다. 정확한 성능비교를 위해 10-Fold cross validation 실험을 수행한 결과, 적응적 방법과 비적응적 방법이 각각 90.5±1.6과 88.7±2.2의 분류율을 보였다.

4.3 적응적 방법의 결과분석

그림 11은 제안하는 방법에서의 오분류 샘플들의 대표적 예를 보여준다. (a)와 (b)는 각각 지문이 건조하여



그림 9 그림 2의 지문영상으로부터 추출한 특징벡터의 패턴




그림 11 적응적 방법을 통한 지문자동분류시스템에서의 오분류 영상 예

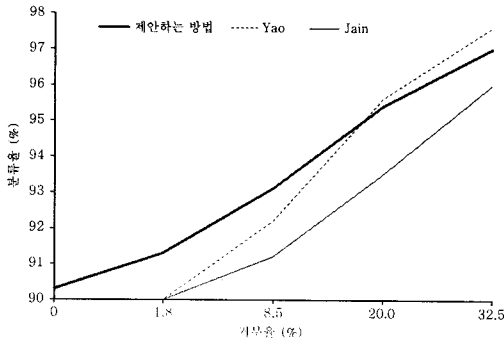


그림 12 제안하는 방법과 기존 방법들의 거부율에 따른 분류성능

나 습하여서 정확히 추출이 안 된 경우로, 정확한 융선 정보를 추출하기 어렵다. (c)는 지문의 흉터로 인해 특이점 정보가 손실된 경우로 분류가 불가능하다. (d)는 지문을 수집하는 과정에서 영상이 훼손된 경우이다. (e)의 지문은 Whorl클래스지만 2개의 삼각주 중에서 하나가 중심점에 매우 인접하게 위치한 경우로, 융선의 흐름 모양에 의해 Righ loop클래스로 오분류한 경우이다.

기존의 지문분류 연구에서는 이와 같이 품질이 좋지 않은 지문들을 특징추출단계나 분류단계에서 거부하였다. 본 논문에서는 기존 연구와 비교를 위해 분류결과의 신뢰도에 따라 샘플을 거부하였다. 먼저 샘플과 가장 유사한 클래스와의 거리 d_1 과 두 번째로 유사한 클래스와의 거리 d_2 를 구한다. 이 때, 두 거리의 차이(d_2-d_1)가 클수록 분류의 신뢰도가 높은 것이기 때문에 이들의 차이가 작은 샘플은 거부한다. 그림 12는 제안하는 방법과 기존의 방법(Jain[5], Yao[6])의 거부율에 따른 분류성능을 나타낸다. Jain과 Yao는 FingerCode를 특징벡터로 사용하였는데, 특징추출과정에서 1.8%의 샘플이 거부되었기 때문에 거부율이 0%일 경우는 적용되지 않는다. 분석결과, 제안하는 방법이 거부율 20%이하의 유의한 수준에서 좋은 성능을 보였다.

5. 결론

지문분류는 지문의 전역적 특징에 따라 미리 정의된

카테고리로 분류하는 기술이다. 지문은 개인마다 고유하기 때문에, 동일한 클래스에 속하는 지문들도 다양한 특성을 보여 정확한 분류가 어렵다. 본 논문에서는 이와 같은 다양한 지문을 효과적으로 분류하기 위하여 적응적 특징추출방법을 제안하였다. 이 방법은 각 지문의 고유한 특징영역을 융선의 방향 변화량이 많은 영역으로 선택하고 이로부터 특징벡터를 추출하여 SVM을 통해 분류한다. 따라서 모든 지문에 대해 동일한 크기의 특징영역을 적용하였던 기존의 비적용적 방법들에 비해 정확한 특징을 추출할 수 있다. 본 논문에서는 고정된 특징영역으로부터 추출한 비적용적 특징과 제안하는 방법인 적응적 특징의 성능을 NIST4 데이터베이스를 이용하여 비교분석하였으며, 이를 통해 제안하는 방법의 우수성을 검증하였다. 적응적 특징영역 선택방법을 지문을 포함한 다양한 영상처리분야의 관심영역기반 특징추출 및 인식기법에 적용하여 기존 방법들의 성능을 향상시킬 수 있을 것으로 기대되며, 향후에는 이에 대한 연구를 진행할 계획이다.

참고문헌

- [1] D. Maltoni, D. Maio, A.K. Jain, and S. Prabhakar, *Handbook of Fingerprint Recognition*, Springer, 2005.
- [2] K. Karu and A.K. Jain, "Fingerprint classification," *Pattern Recognition*, Vol.29, No.3, pp. 389-404, 1996.
- [3] R. Cappelli, A. Lumini, D. Maio, and D. Maltoni, "Fingerprint classification by directional image partitioning," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.21, No.5, pp. 402-421, 1999.
- [4] J.-H. Chang and K.-C. Fan, "A new model for fingerprint classification by ridge distribution sequences," *Pattern Recognition*, Vol.35, No.6, pp. 1209-1223, 2002.
- [5] A. K. Jain, S. Prabhakar, and L. Hong, "A multi-channel approach to fingerprint classification," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.21, No.4, pp. 348-359, 1999.
- [6] Y. Yao, G.L. Marcialis, M. Pontil, P. Frasconi, and

- F. Roli, "Combining flat and structured representations for fingerprint classification with recursive neural networks and support vector machines," *Pattern Recognition*, Vol.36, No.2, pp. 397-406, 2003.
- [7] J.-K. Min, J.-H. Hong, and S.-B. Cho, "Fingerprint classification using multiple decision templates with SVM," *Journal of KISS: Software and Applications*, Vol.32, No.11, pp. 1136-1146, 2005.
- [8] L. Wang and M. Dai, "Application of a new type of singular points in fingerprint classification," *Pattern Recognition Letters*, Vol.28, No.13, pp. 1640-1650, 2007.
- [9] A. Jain, L. Hong, and R. Bolle, "On-line fingerprint verification," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.19, No.4, pp. 302-314, 1997.
- [10] C.I. Watson and C.K. Wilson, Fingerprint Database. National Institute of Standards and Technology, Special Database 4, FPDB, 1992.
- [11] D. L. Davies and D. W. Bouldin, "A cluster separation measure," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.1, pp. 224-227, 1979.



민 준 기

2004년 연세대학교 기계전자공학부(학사)
 2006년 연세대학교 컴퓨터과학과(석사)
 2006년~현재 연세대학교 컴퓨터과학과
 박사과정. 관심분야는 패턴인식, 영상처리



조 성 배

1988년 연세대학교 전산학과(학사). 1990
 년 한국과학기술원 전산학과(석사). 1993
 년 한국과학기술원 전산학과(박사). 1993
 년~1995년 일본 ATR 인간정보통신연
 구소 객원 연구원. 1998년 호주 Univ. of
 New South Wales 초청연구원. 1995
 년~현재 연세대학교 컴퓨터과학과 정교수. 관심분야는 신
 경망, 패턴인식, 지능정보처리