

다중결정템플릿기반 SVM결합모델을 통한 지문분류

민준기⁰, 홍진혁, 조성배
연세대학교 컴퓨터과학과
생체인식연구센터

{loomlike⁰, hjinh}@sclab.yonsei.ac.kr sbcho@cs.yonsei.ac.kr

Fingerprint Classification Using SVM Combination Models based on Multiple Decision Templates

Jun-Ki Min⁰, Jin-Hyuk Hong, Sung-Bae Cho
Department of Computer Science, Yonsei University
Biometrics Engineering Research Center

요 약

지문을 5가지 클래스로 나누는 헨리시스템을 기반으로 신경망이나 SVM(Support Vector Machines) 등과 같은 다양한 패턴분류 기법들이 지문분류에 많이 사용되고 있다. 특히 최근에는 높은 분류 성능을 보이는 SVM 분류기의 결합을 이용한 연구가 활발히 진행되고 있다. 지문은 클래스 구분이 모호한 영상이 많아서 단일결합모델로는 분류에 한계가 있다. 이를 위해 본 논문에서는 새로운 분류기 결합모델인 다중결정템플릿(Multiple Decision Templates, MuDTs)을 제안한다. 이 방법은 하나의 지문클래스로부터 서로 다른 특성을 갖는 클러스터들을 추출하여 각 클러스터에 적합한 결합모델을 생성한다. NIST-database4 데이터로부터 추출한 핑거코드에 대해 실험한 결과, 5클래스와 4클래스 분류문제에 대하여 각각 90.4%와 94.9%의 분류성능(거부율 1.8%)을 획득하였다.

1. 서 론

지문분류는 대규모 자동지문식별시스템에서 식별시간 감소를 위해 지문매칭단계에 앞서 수행된다. 지문분류는 주로 특이점(중심점과 삼각주)의 위치와 개수에 따라 그림 1과 같이 Whorl(W), Right loop(R), Left loop(L), Arch(A), Tented arch(T)의 다섯 가지 클래스로 분류하는 헨리시스템을 따른다[1].

지문분류에는 신경망, KNN(K-Nearest Neighbor), SVM(Support Vector Machine) 등의 분류기들이 많이 사용되는데, 분류성능을 높이기 위하여 다수의 분류기들을 결합하는 방법들이 함께 연구되고 있다[2]. 특히 SVM은 다른 분류기들에 비해 좋은 분류 성능을 보이는데, 이는 이진분류기이기 때문에 지문분류를 위해서는 논리적 조합으로 개별 분류기를 생성한 뒤 이를 결합하는 기술이 필요하다[3]. 분류기 결합방법으로는 분류기 출력 값들의 평균으로 각 클래스의 결정템플릿을 만들고 입력 값과의 유사도를 비교하여 분류를 수행하는 결정템플릿(Decision Templates)이 좋은 성능을 보이고 있다[4]. 하지만 이는 데이터의 특징을 클래스별로 하나의 템플릿으로 축약시키기 때문에, 지문과 같이 하나이상의 클래스 특징을 복합적으로 갖는 분류문제에 적용시키기에는 한계가 있다.




그림 1. 헨리시스템의 5가지 클래스. (a) Whorl, (b) Right loop, (c) Left loop, (d) Arch, (e) Tented arch.

본 논문에서는 클래스의 다양한 특징들을 모델링하는 다중결정템플릿(Multiple Decision Templates)을 제안하고, 이를 이용하여 SVM분류기의 결합을 수행한다.

2. 관련연구

2.1 핑거코드

핑거코드(FingerCode)는 Jain이 제안한 필터기반 특징 추출 방법으로, 이를 이용하여 NIST-database4로부터 특징을 추출하여 핑거코드데이터를 생성한다. 이는 중심점을 기준으로 48개의 섹터로 지문영상을 나눈 뒤 0°, 45°, 90°, 135°의 방향성을 갖는 4개의 가보필터를 적용시킨다. 가보필터는 대역여과기이기 때문에 동일한 방향성의 융선 영상은 선명해지고, 그렇지 않은 영상은 뭉개진다. 변환된 영상은 각 섹터별 픽셀 값의 표준편차가 계산되어 192차원의 특징벡터를 생성한다. 본 논문에서는 이 데이터를 사용하여 제안하는 방법의 성능을 검증하였다.

2.2 SVM

SVM은 학습데이터를 비선형 매핑함수를 이용하여 입력 샘플 공간으로부터 선형 초평면이 만들어 질 수 있는 고차원 특징 공간으로 매핑하고, 인식에러가 최소가 되게 하는 최적 초평면을 찾는다[5]. 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 a_i 는 x_i 가 초평면을 구성하는 샘플인 경우 0이 아닌 값을 갖고, 그렇지 않을 경우에는 0의 값을 갖는 계수이다. 커널함수 $K(x, x_i)$ 는 비선형 매핑함수의 내적계산을 함수 형식으로 치환하여 계산을 간단하게 해주며, 선형(Linear), 다항식(Polynomial), 가우시안(Gaussian), 시그모이드(Sigmoid) 커널 등이 있다. 식 (2)는 좋은 성능으로 많이 사용되는 가우시안 커널의 식이다.

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

다중분류문제를 해결하기 위한 SVM의 대표적인 조합 전략으로 one-vs-all, pairwise, complete-code가 있다 [6].

3. 다중결정템플릿

3.1 다중결정템플릿의 생성

본 논문에서는 제안하는 방법인 다중결정템플릿을 이용하여 SVM의 one-vs-all 조합을 결합하여 지문분류를 수행한다. 학습데이터 $x = (x_1, \dots, x_n)$ 를 이용하여 생성한 L 개의 SVM(D_1, \dots, D_L)의 출력 값인 결정프로파일 $LP_c(x)$ 을 레이블에 따라 Whorl부터 Tented Arch까지 5가지 클래스로 나눈다. 이를 각각 식 (3)의 SOM알고리즘으로 $N \times N$ 클러스터로 묶는다. SOM맵의 (i, j) 에 위치한 클러스터의 가중치를 $w_{i,j}$ 라 하면, 입력벡터 x 는 유클리드 거리 식을 사용하였을 때, 식 (3)에 의해 클러스터 (k, l) 로 결정된다.

$$\|x - w_{k,l}\| = \min_{i,j=1,\dots,N} \|x - w_{i,j}\| \quad (3)$$

각 클래스의 결정프로파일들은 클래스 내의 여러 클러스터로 분해되어 서로 다른 특징을 지닌 그룹을 형성한다. 각 클러스터의 결정프로파일들은 식 (4)에 의해 평균값이 계산되어 클래스별로 $N \times N$ 개의 결정템플릿을 생성한다. 그림 2는 다중결정템플릿의 생성과정을 보여준다.




그림 2. 학습데이터를 이용한 다중결정템플릿의 생성

$$DT_c^{k,l} = \begin{bmatrix} dt_c^{k,l}(1,1) & \dots & dt_c^{k,l}(1,M) \\ \vdots & dt_c^{k,l}(y,z) & \vdots \\ dt_c^{k,l}(L,1) & \dots & dt_c^{k,l}(L,M) \end{bmatrix}, \quad (4)$$

$$dt_c^{k,l}(y,z) = \frac{\sum_{i=1}^n ind_c^{k,l}(x_i) d_{y,z}(x_i)}{\sum_{i=1}^n ind_c^{k,l}(x_i)}$$

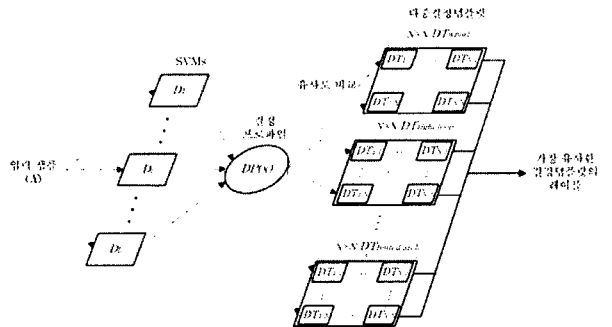


그림 3. 다중결정템플릿을 이용한 분류과정

3.2 다중결정템플릿을 이용한 분류

다중결정템플릿을 이용한 분류는 [4]의 단일결정템플릿과 마찬가지로 입력된 샘플의 결정프로파일과 가장 유사한 결정템플릿들의 레이블로 클래스를 결정한다. 그림 3은 분류과정으로서, L 개의 SVM으로부터 얻은 입력샘플의 결정프로파일을 학습단계에서 각 클래스별로 생성한 $N \times N$ 개의 결정템플릿과 비교하는 과정을 보여준다. 결정프로파일과 결정템플릿간의 유사도계산은 [4]와 같이 거리나 유사도를 계산하는 다양한 방법들이 모두 적용될 수 있는데, 본 논문에서는 간단하면서 많이 사용되는 해밍거리(식 5)와 유클리드 거리(식 6) 두 가지 방법을 이용하여 실험하였다.

$$\min_{c=1,\dots,M} (\min_{i,j=1,\dots,n} dst_c^{i,j}(x)),$$

$$dst_c^{i,j}(x) = \sum_{y=1}^L \sum_{z=1}^M |dt_c^{i,j}(y,z) - d_{y,z}(x)| \quad (5)$$

$$dst_c^{i,j}(x) = \sqrt{\sum_{y=1}^L \sum_{z=1}^M (dt_c^{i,j}(y,z) - d_{y,z}(x))^2} \quad (6)$$

4. 실험 및 결과

4.1 실험환경

본 논문에서는 제안하는 다중결정템플릿의 성능을 검증하기 위해 NIST-database4의 첫 번째 등록된 2000개의 지문(F0001~F2000)을 학습데이터로, 두 번째 등

록된 2000개의 지문(S0001~S2000)을 평가 데이터로 사용하였다. 분류를 위한 특징은 Jain의 핑거코드 데이터를 +1에서 -1 사이의 실수 값으로 정규화하여 사용하였는데, 이 데이터는 추출과정에서 거부된 지문영상이 있기 때문에 학습데이터와 평가 데이터에 각각 1.4%와 1.8%의 거부율이 적용되었다.

분류기는 LIBSVM(<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>)의 가우시안 커널을 사용하였으며, SOM맵의 크기를 1×1에서 9×9까지 변화시켜가며 적합한 크기를 선택하여 사용하였다.

4.2 실험결과

다중결정템플릿으로 one-vs-all SVM을 결합하여 지문분류를 수행한 결과 5클래스와 4클래스 분류에 있어서 각각 90.4%와 94.9%의 분류성능을 보였다. 5클래스 분류 결과에 대한 혼동행렬은 표 1과 같다. 기존의 단일결합모델과의 비교실험을 통해 그림 4와 같이 하나 이상의 클래스 특징을 갖는 모호한 지문영상을 정확히 분류하는 것을 확인할 수 있었다.

제안하는 방법과 다른 결합방법들의 비교실험을 위해 SVM의 one-vs-all(OVA), pairwise(PW) complete code(CC)조합[6]에 대해 winner-takes-all(WTA), error-correcting-code(ECC), behavior knowledge space(BKS), 단일결정템플릿(DT)의 결합방법을 이용하여 지문분류실험을 수행하였다. 유사도 비교는 해밍거리(HM)와 유클리드거리(EU)를 사용하였고, BKS의 경우 샘플이 동표를 가질 경우 winner-takes-all 방법을 사용하여 분류하였다. 각 결합방법의 분류율 결과는 표 2와 같다. 표의 결과에서 알 수 있듯이, 제안하는 방법인 다중결정템플릿(MuDTs:EU)이 가장 높은 성능인 89.5~90.4%의 분류율을 보였다.

표 1. 제안하는 방법의 혼동행렬

	W	R	L	A	T
W	380	6	7	0	1
R	9	369	1	5	17
L	8	0	366	14	10
A	1	4	1	356	50
T	1	10	6	38	304

표 2. 여러 결합방법의 성능비교(%)

	OVA	PW	CC
WTA	90.1	87.7	90.0
ECC:HM:EU	90.1	88.6	90.0
BKS	88.8	89.4	89.3
DT:HM	89.6	87.6	89.6
DT:EU	89.8	88.3	89.5
MuDTs:HM	90.3	89.3	90.3
MuDTs:EU	90.4	89.5	90.3



그림 4. 다중결정템플릿을 통해 분류한 모호한 지문영상의 예. (a) Tented arch와 유사한 Right loop, (b) Tented arch와 유사한 Arch, (c) Tented arch와 유사한 Left loop, (d) Left loop와 유사한 Tented arch

5. 결론

본 논문에서는 지문영상의 효과적 분류를 위한 다중결정템플릿기반 SVM 결합모델을 제안하였다. NIST-database4로 핑거코드 특징을 사용하여 실험한 결과 5클래스 분류에 대하여 90.4%의 분류율(거부율 1.8%)로, ECC, BKS, 단일결정템플릿 등의 기존 결합방법들보다 높은 분류성능을 보였다. 특히 기존의 방법으로는 분류가 어려웠던 여러 클래스의 특징이 중복되어있는 지문영상들을 분류하여, 템플릿을 클래스 내부의 특징에 따라 세분화하는 것이 효과적임을 입증하였다. 추후에는 다중템플릿의 이점을 극대화하기 위한 효과적인 분류기 조합 방법과 데이터 개수에 따른 적절한 클러스터맵 크기에 대한 연구를 수행할 계획이다.

감사의 글

본 연구는 생체인식연구센터(BERC)를 통해 한국과학재단(KOSEF)에서 지원받았음.

참고문헌

- [1] E. R. Henry, *Classification and Uses of Finger Prints*, London: Routledge, 1900.
- [2] A. K. Jain, et al., "A multichannel approach to fingerprint classification," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 21, no. 4, pp. 348-359, 1999.
- [3] Y. Yao, et al., "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.
- [4] L. I. Kuncheva, et al., "Decision templates for multiple classifier fusion: An experimental comparison," *Pattern Recognition*, vol. 34, no. 2, pp. 299-314, 2001.
- [5] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines*, Cambridge University Press, 2000.
- [6] C.-W. Hsu and C.-J. Lin, "A comparison of methods for multiclass support vector machines," *IEEE Trans. Neural Networks*, vol. 13, no. 2, pp. 415-425, 2002.