

효과적인 지문분류를 위한 SOM기반 OVA SVM의 결합 기법

홍진혁^o 민준기 조성배
연세대학교 컴퓨터과학과
생체인식연구센터

(hjinh, loomlike)@sclab.yonsei.ac.kr, sbcho@cs.yonsei.ac.kr

SOM-based Combination Method of OVA SVMs for Effective Fingerprint Classification

Jin-Hyuk Hong^o Jun-Ki Min Sung-Bae Cho
Dept. of Computer Science, Yonsei University
Biometrics Engineering Research Center

요 약

대규모 지문인식 시스템에서 비교해야할 지문의 수를 줄이기 위해서 지문분류는 필수적인 과정이다. 최근 이진분류기인 지지 벡터 기계(Support Vector Machine: SVM)를 이용한 지문분류 기법이 많이 연구되고 있다. 본 논문에서는 다중부류 지문분류에 적합하도록 자기 구성 지도(Self-Organizing Map:SOM)를 이용하여 OVA(One-Vs-All) SVM들을 결합하는 지문분류 기법을 제안한다. SOM을 이용하여 OVA SVM들을 동적으로 결합하기 위한 결합 지도를 생성하여 지문분류 성능을 높인다. 지문분류에 있어 대표적인 NIST-4 지문 데이터베이스를 대상으로 Jain이 구축한 FingerCode 데이터베이스에 제안하는 방법을 적용하여 1.8%의 거부율에서 90.5%의 분류율을 획득하였으며, 기존의 결합 방법인 승자독식(Winner-takes-all)과 다수결 투표(Majority vote)보다 높은 성능을 확인하였다.

1. 서론

지문분류는 대규모 데이터베이스의 지문인식 시스템에서 비교해야할 지문 템플릿의 수를 줄여 빠른 처리를 제공하기 위한 매우 중요한 과정이다[1]. 지문분류에서 많이 사용되는 Henry 시스템은 그림 1에서와 같이 지문을 5개의 부류로 구분한다. 지문분류 기술의 평가에 많이 사용되는 NIST 데이터베이스도 Henry 시스템을 따르며[2], 이를 이용한 지문분류 연구가 활발히 진행되고 있다. 용선 방향성, 중심점, 의사 용선[2], 용선 그림자[1], 구분된 방향 영상(Segmented directional image)[3] 및 FingerCode[4] 등 매우 다양한 특징이 지문영상에서 추출되어 이들 지문분류 연구에 사용되고 있다.



그림 1. Henry 시스템의 지문 5분류

중심점이나 의사 용선 등의 구조적 특징을 이용한 규칙 기반 분류 기법이 연구될 뿐만 아니라, 방향성, 용선 그림자 및 FingerCode 등의 지문의 통계적 특징을 바탕으로 다양한 기계 학습 기법을 적용한 연구도 활발히 진행되고 있다. 전자는 분류결과를 해석하기에는 용이하지만 잡음에 취약하다는 한계가 있고, 후자의 경우에는 잡음에 강하다는 장점이 있다[1,4]. 지문 영상은 종종 사용자나 환경의 영향으로 잡음을 가지기 때문에 잡음에 강한 통계적 특징이 보다 효과적일 수 있다. 특히, FingerCode는 대표적인 지문특징으로 특징점이나 용선과 골의 전역적인 흐름에 대한 정보를 포함하여 지문분류에 많이 사용

되고 있다. FingerCode는 먼저 중심점을 찾고, 섹터를 구분하여 Gabor 필터를 적용한다. Gabor 필터의 각 방향성에 대해 영상의 각 섹터의 Gray 수준의 표준편차를 계산하여 특징벡터를 구성한다 [4].

본 논문에서는 지문분류에 있어 대표적인 특징인 FingerCode를 사용하며, SVMs과 SOM을 효과적으로 결합한 지문분류 기법을 제안한다. SVM은 통계적 학습 이론을 기반으로 한 대표적인 이진 분류기이며[3], OVA는 이를 다중부류 분류에 적용하기 위한 분류기 구성 방법이다. Kohonen이 제안한 SOM은 클러스터링을 위한 대표적인 비교사 학습 방법으로, 입력된 데이터의 분류를 찾는데 유용하다[5]. 보통 같은 유형의 지문이라도 편차가 심하기 때문에, 본 논문에서는 2 단계로 제안하는 방법을 구성하여 입력된 지문 영상의 특성에 따라 동적으로 적절한 SVM이 선택되어 분류를 수행한다. 먼저 SOM을 이용하여 입력 영상을 클러스터링한 후 OVA SVMs를 해당 클러스터에 적합하도록 정렬하여 5 분류 지문분류를 수행한다.

2. OVA SVM들을 이용한 다중부류 지문분류

구조적 위험 최소화를 기반으로 하는 SVM은 부류 사이를 구분하는 최적의 초평면을 찾으며, 많은 연구에서 신경망과 같은 기존의 기계학습 기법보다 나은 일반화 성능을 내었다. SVM은 기본적으로 모든 학습 샘플에 대해 다음의 수식을 만족하는 초평면 (w, b)를 가지는 이진 분류기이다.

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad (1)$$

x_i 는 학습 샘플이고, y_i 는 x_i 의 클래스 레이블로서 $\{+1, -1\}$ 값을 가진다. 초평면은 $w \cdot x + b = 0$ 으로 정의되며, 수식 (2)는 두 부류 사이의 마진(Margin)을 나타낸다. 마진을 최대화하는 것, 즉 오류를 최소화하면 수식 (1)을 만족하는 최적의 초평면을 구할 수 있다.

$$\min \left\{ \frac{1}{2} \|w\|^2 \right\} / \|w\| \quad (2)$$

SVM은 이진분류기이기 때문에 다중부류 분류에 적용하기 위해서는 "One-Vs-All," "Pairwise"나 DAG (Directed Acyclic Graph) 등과 같은 분류기 구축 전략이 필요하다. 이진분류기 구축의 대표적인 방법으로서 OVA는 부류 개수 k 만큼의 SVM 모델을 생성한다. i 번째 SVM은 i 번째 부류에 속하는 샘플은 모두 양의 부류로, 그 외의 샘플은 모두 음의 부류로 구분하여 분류를 수행한다.

i 번째 SVM에 대해서 임의로 생성된 두 부류 사이의 최대 마진 $2/\|w_i\|$ 는 다음의 수식으로 구해진다.

$$y'_j (w_i \cdot x_j + b_i) - 1 \geq 0, \quad \text{if } y_j = i \text{ then } y'_j = 1 \text{ else } y'_j = -1 \quad (3)$$

k 개의 초평면 $(w_1, b_1), \dots, (w_k, b_k)$ 를 구한 후에, 샘플 x 는 각 결정함수로부터 얻어진 값 중에서 가장 큰 값을 가지는 것의 부류로 분류가 된다.

$$\text{class}(x) = \arg_{i=1, \dots, k} \max(w_i x + b_i) \quad (4)$$

3. SOM을 이용한 SVM 분류기의 동적 선택

지문분류는 부류 간에는 큰 변화가 있고 부류 내에서는 적은 변화가 있는 5 부류로 지문영상을 분류한다[4]. 기존의 OVA SVM은 다수결 투표나 승자독식 같은 정적 결합 전략을 채택하여 분류를 수행하였기 때문에 지역적 정확성을 고려하지 않았다. 따라서 지역적 정확성을 고려하여 분류를 수행한다면 보다 나은 분류 성능을 획득할 수 있다[6]. 이를 위한 대표적인 방법인 동적 분류기 선택 기법에서는 특징공간을 다수의 분류기로 구분하여 각 부분에 최적인 분류기를 결정한다. 특징공간에서 새로운 샘플에 대응하는 분류기가 분류를 수행한다.

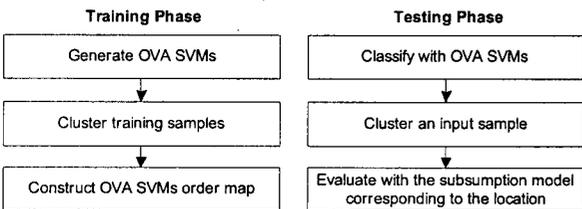


그림 2. 제안하는 방법의 동작 순서

본 논문에서는 그림 2에서와 같이 학습 단계를 3 과정으로 구성한다. 먼저 OVA SVM들을 생성하고, 학습 샘플을 클러스터링한 후 각 클러스터에 적절한 OVA SVM들이 정의되어 있는 순서 지도를 구성한다. Jain 등이 제안한 FingerCode를 이용하여 5개의 SVM을 OVA 전략에 따라 학습한다. 각 SVM은 입력 지문이 초평면으로부터 얼마나 떨어져 있는지를 나타내는 마진을 출력한다. 종종 불확실한 영상이 있기 때문에, 결정적 접근법으로는 높은 성능을 얻기가 어렵다[3]. 따라서 본 논문에서는 데이터의 지역성을 고려하여 이러한 문제를 해결한다.

샘플들 사이의 지역성을 측정하기 위해서 본 논문에서는 Kohonen의 자기 구성 지도를 이용하여 OVA SVM들의 출력 값을 바탕으로 샘플을 클러스터링한다. x 를 OVA SVM들의 출력값으로 구성된 입력 벡터라고 가정하면, SOM의 각 출력 노드 i 에는 가중치 벡터 w_i 가 부여된다. x 와 w_i 사이의 유클리드

거리가 최소가 되는 승자 출력 노드 w_c 는 다음과 같이 구해진다.

$$\|x - w_c\| = \min \|x - w_i\| \quad (5)$$

승자 노드 주위의 이웃 노드 N_c 를 포함해서 모든 노드의 가중치를 수식 (6)에 근거하여 시간 t 에서 시간 $t+1$ 로 갱신한다. 단, $a(t)$ 는 학습율이며 0과 1사이의 값을 갖는다.

$$w_i(t+1) = w_i(t) + a(t)[x(t) - w_i(t)] \quad (6)$$

학습 샘플에 대한 클러스터링이 끝나면, 그림 3에서와 같이 학습 샘플의 분류를 나타내는 지도를 구성한다. 최종적으로 지도의 각 셀에서의 OVA SVM들의 순서를 해당 셀에서의 각 부류의 샘플의 수와 분류율에 따라 결정한다. 하나의 셀에서 whorl 지문이 다른 지문보다 많고 분류율도 높다면, whorl을 분류하는 SVM이 다른 OVA SVM들보다 먼저 평가된다. 복수의 OVA SVM이 양의 값을 가지는 애매모호한 지문영상이 있기 때문에, OVA SVM의 평가 순서를 샘플의 수와 분류율에 따라 정함으로써 이런 문제를 해결할 뿐만 아니라 확률적으로 오류를 최소화한다.

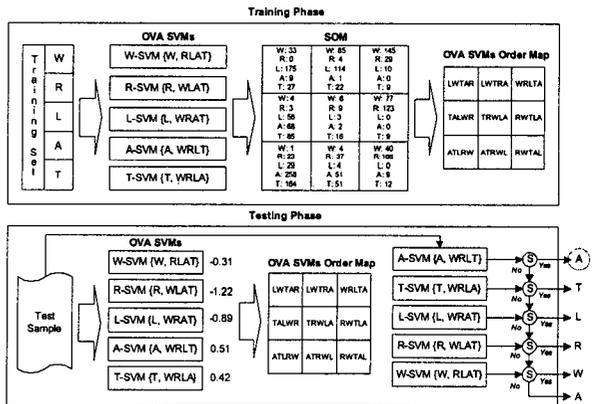


그림 3. 제안하는 방법의 구조

지문 분류는 먼저 입력 샘플을 OVA SVM을 이용하여 분류하고, SOM을 이용하여 그 결과를 클러스터링 한다. 입력 샘플에 대한 클러스터가 결정되면, 그림 3에서와 같이 해당 클러스터의 OVA SVM의 순서를 고려하여 OVA SVM 포섭구조를 구성한다. 만약 해당 클러스터의 값이 "ATLRW" 이면 arch를 분류하는 SVM이 먼저 arch 클래스에 속하는지 안 속하는지를 결정한다. 만약 속하지 않는다고 결정되면 부류가 결정될 때까지 다음 부류에 대한 SVM이 소속여부를 평가한다. 모든 OVA SVM이 속하지 않는다고 결정할 경우에 샘플의 수와 분류율이 임계치를 넘는다면 처음의 클래스로 분류시켜 확률적으로 오류가 최소가 되도록 한다. 결국 포섭구조로 구성된 OVA SVM들은 클러스터에 따라 다르게 구성되어 입력 샘플의 지역적 특성에 따라 동적으로 분류를 수행하여 보다 높은 분류 성능을 획득한다.

4. 실험 및 결과

4.1 실험환경

Jain 등이 수행한 것과 같이, NIST-4에서 추출한 FingerCode를 이용하여 제안하는 방법을 검증하였다[4].

FingerCode는 4 방향(0°, 45°, 90°, 135°) 가보 필터에 대해 총 48 섹터 Gray 값의 표준편차로 구성된 192개의 실수 특징값 벡터로 이루어져있다. 평가 데이터는 총 1,973개의 학습 샘플과 1,964개의 테스트 샘플로 되어 있으며, 기본적으로 테스트 샘플은 1.8%로 거부되었다.

4.2 결과분석

RBF 커널 함수를 이용한 OVA SVM들은 애매모호한 경우는 모두 거부하는 다수결 투표 전략을 고려하였을 때, 5 부류 분류에 대해 93.9%의 정확률을 획득하였다. 이 때, 테스트 샘플의 12.8%가 애매모호한 경우로 분류가 거부되었다. 반면에 SVM들에서 가장 높은 값을 가지는 것의 부류를 선택하는 승자독식 전략의 경우에는 1.8%의 거부율에서 90.2%의 분류율을 획득하였다. 제안하는 방법은 표 1에서와 같이 다른 방법에 비해 높은 분류 성능을 획득하였다. Arch와 tented arch를 하나의 부류로 고려한 4 부류 분류에서도 비슷한 결과를 얻었다. 거부율 1.8%와 14.4%에서의 제안하는 방법의 혼동 행렬은 각각 표 2와 표 3과 같다.

표 1. 지문분류 결과

방법	거부율 (%)	1.8	4.8	10.3	14.4
승자독식	5 부류	90.2	91.1	92.8	93.9
	4 부류	94.7	95.6	96.5	97.0
다수결 투표	5 부류	-	-	-	93.9
	4 부류	-	-	-	97.0
제안하는 방법	5 부류	90.5	91.5	93.1	93.9
	4 부류	94.8	95.7	96.6	97.0

표 2. 거부율 1.8%에서의 제안하는 방법의 혼동 행렬

	W	R	L	A	T
W	381	6	7	0	0
R	6	364	2	4	17
L	6	0	377	9	9
A	2	7	5	345	50
T	1	7	14	35	310

표 3. 거부율 14.4%에서의 제안하는 방법의 혼동 행렬

	W	R	L	A	T	거부
W	366	5	4	0	0	19
R	3	335	0	3	11	37
L	6	0	347	5	5	33
A	0	0	0	304	32	70
T	0	4	6	20	256	93

그림 4는 SOM을 이용하여 학습 샘플을 클러스터링한 결과를 보여준다. 3x3 그리드가 지문 샘플의 분포를 표현하고 OVA SVM들의 순서 지도를 생성하기 위해 사용되었다. 클러스터링된 결과를 보면, Left loop 지문은 왼쪽 위에 많이 분포하였고, right loop 지문은 지도의 오른쪽에 많이 분포하였다. Arch와 tented arch 지문은 왼쪽 밑에 분포하여, 이들 두 지문이 많이 유사함을 보여주었다. 결과에서 알 수 있듯이, whorl

지문은 left loop 지문보다 right loop 지문과 더 유사함을 보였다. 샘플의 분포를 나타내는 SOM 지도 결과를 바탕으로 다음과 같이 OVA SVM들의 순서 지도를 생성하여, 입력된 지문 영상의 지역적 특성을 고려한 지문분류가 수행되도록 하였다.

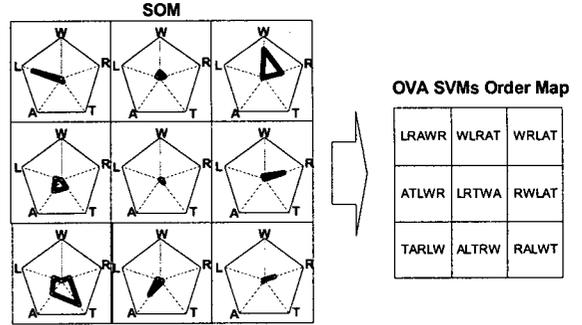


그림 4. SOM으로부터 획득된 샘플 분포 지도

5. 결론

본 논문에서는 NIST-4 데이터베이스에 대한 기존의 분류 결과보다 향상된 성능의 지문분류 방법을 제안하였다. FingerCode를 이용한 OVA SVM들은 높은 분류성능을 획득하였으며, SOM을 이용한 동적 분류기 결합은 전체 분류성능을 더욱 향상시켰다. 1.8%의 거부율 아래, 5 부류 지문분류에 대해서 90.5%의 분류성능을, 4 부류 지문분류에 대해서 94.8%의 분류성능을 획득하였다. 향후에는 보다 안정된 동적 분류기 결합을 위해 계층적 클러스터링 기법을 적용하고, 다양한 평가 데이터를 통해 제안하는 방법의 유용성을 검증할 것이다.

감사의 글

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

참고문헌

- [1] A. Senior, "A combination fingerprint classifier," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 23, no. 10, pp. 1165-1174, 2001.
- [2] Q. Zhang and H. Yan, "Fingerprint classification based on extraction and analysis of singularities and pseudo ridges," *Pattern Recognition*, vol. 37, no. 11, pp. 2233-2243, 2004.
- [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] A. Jain, et al., "A multichannel approach to fingerprint classification," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 21, no. 4, pp. 348-359, 1999.
- [5] A. Laha and N. Pal, "Dynamic generation of prototypes with self-organizing feature maps for classifier design," *Pattern Recognition*, vol. 34, no. 2, pp. 315-321, 2001.
- [6] K. Woods, "Combination of multiple classifiers using local accuracy estimates," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 19, no. 4, pp. 405-410, 1997.