

OVA SVM의 동적 결합을 이용한 효과적인 지문분류

홍진혁^o 조성배
연세대학교 컴퓨터과학과
생체인식연구센터

hjinh@sclab.yonsei.ac.kr, sbcho@cs.yonsei.ac.kr

Effective Fingerprint Classification with Dynamic Integration of OVA SVMs

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

요 약

지문 벡터 기계(Support Vector Machine: SVM)를 이용한 다중분류 분류기법이 최근 활발히 연구되고 있다. SVM은 이진분류기이기 때문에 다중분류 분류를 위해서 다수의 분류기를 구성하고 이들을 효과적으로 결합하는 방법이 필요하다. 본 논문에서는 기존의 정적인 다중분류기 결합 방법과는 달리 포섭구조의 분류모델을 확률에 따라 동적으로 구성하는 방법을 제안한다. 확률적 분류기인 나이브 베이즈 분류기(NB)를 이용하여 입력된 샘플의 각 클래스에 대한 확률을 계산하고, OVA (One-Vs-All) 전략으로 구축된 다중의 SVM을 획득된 확률에 따라 포섭구조로 구성한다. 제안하는 방법은 OVA SVM에서 발생하는 중의적인 상황을 효과적으로 처리하여 고성능의 분류를 수행한다. 본 논문에서는 지문분류 문제에서 대표적인 NIST-4 지문 데이터베이스를 대상으로 제안하는 방법을 적용하여 1.8%의 거부율에서 90.8%의 분류율을 획득하였으며, 기존의 결합 방법인 다수결 투표(Majority vote), 승자독식(Winner-takes-all), 행동지식공간(Behavior knowledge space), 결정템플릿(Decision template) 등보다 높은 성능을 확인하였다.

1. 서론

지문분류는 대규모 데이터베이스의 지문인식 시스템에서 비교해야 할 지문 템플릿의 수를 줄여 빠르게 처리하기 위해 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. 융선 방향성, 중심점, 의사 융선[2], 융선 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 융선 등의 구조적 특징을 이용한 규칙 기반 분류 기법이 연구될 뿐만 아니라, 방향성, 융선 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 사용자 환경의 영향으로 잡음이 생기기 때문에 잡음에 강한 통계적 특징이 보다 효과적일 수 있다. 특히, FingerCode는 대표적인 지문특징으로 특징점이나 융선과 골의 전역적인 흐름에 대한 정보를 포함하여 지문분류에 많이 사용된다[4].

본 논문에서는 SVM기반의 지문분류 성능을 개선하기 위해서, OVA SVM을 이용한 분류에서 종종 발생하는 중의적 상황을 확률적 우선순위로 해결하는 방법을 제안한다. 지문분류의 대표적인 특징인 FingerCode를 사용하여 SVM을 OVA 전략으로 학습하고 포섭구조로 분류모델을 구성한다. 포섭구조 내부의 OVA SVM은 특이점과 의사융선 정보로 학습된 NB가 계산한 각 클래스의 확률값에 따라 정렬된다. 제안하는 방법은 확률적으로 SVM의 순위를 결정하기 때문에 동시에 다수의 SVM이 만족하는 경우를 효과적으로 해결하여 높은 분류 성능을 획득한다.

2. OVA SVM의 확률적 구성기반 지문분류

제안하는 방법은 그림 2와 같이 특이점과 의사융선 정보를 바탕으로 학습된 NB가 FingerCode로 학습된 OVA SVM의 평가순위를 결정한다. 입력된 샘플에 따라 동적으로 구성된 포섭구조의 분류모델은 각 OVA SVM을 순차적으로 평가하여 분류를 수행한다. 복수의 SVM이 동점을 내거나 하나도 만족을 하지 않는 경우는 확률적 순위에 따라 처리하여 효과적으로 해결된다. 샘플이 입력되면 그림 3에서와 같이 NB로부터 획득된 확률값에 따라 OVA SVM을 정렬하고 포섭구조 형태로 분류를 수행한다.

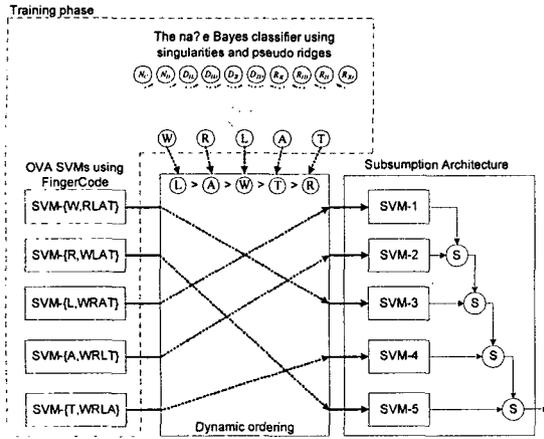


그림 2. 제안하는 동적 지문분류 모델

```

prob[5] = {pW, pR, pL, pA, pT}
// prob[] is calculated by the naive Bayes classifier
order[5] = {0, 1, 2, 3, 4}
o-svm[5] = {mW, mR, mL, mA, mT}
// o-svm[] is obtained by the OVA SVMs

// ordering
for(i=0; i<5; i++)
for(j=i+1; j<5; j++)
if(prob[j] < prob[i])
{ int iTemp = prob[i]; prob[i] = prob[j];
  prob[j] = iTemp;

  iTemp = order[i]; order[i] = order[j];
  order[j] = iTemp; }

// classifying
if(prob[order[0]] < r1) // r1 is a rejection threshold
return reject;
for(i=0; i<5; i++)
{ if(o-svm[order[i]] >= a) // a is a threshold
  { if(o-svm[order[i]] < r2) // r2 is a rejection threshold
    return reject;
    return order[i]; } }
return order[0];
    
```

그림 3. 지문 분류 과정

제안하는 지문분류를 수행하기 위해서, 먼저 OVA 전략으로 SVM을 학습한다. 이 때, 기존 연구에서 우수한 분류 성능을 보인 특징인 FingerCode[4]를 사용한다. 구조적 위험을 최소화하는 SVM은 부류 사이를 구분하는 최적의 초평면을 찾을 뿐만 아니라 많은 연구에서 신경망과 같은 기존의 기계학습 기법에 비해 나은 일반화 성능을 보였다. SVM은 모든 학습 샘플에 대해 다음의 수식을 만족하는 초평면 (w, b)를 찾는다.

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

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 분류를 위해서 "One-Vs-All," "Pairwise"나 DAG (Directed Acyclic Graph) 등을 바탕으로 다수의 분류기를 구성해야 한다. 본 연구에서는 이진분류기 구축의 대표적인 방법인 OVA를 이용한다. OVA는 부류 개수 k 만큼의 SVM 모델을 생성하는데, i 번째 SVM은 i 번째 부류에 속하는 샘플은 모두 양의 부류로, 그 외의 샘플은 모두 음의 부류로 분류한다. 제안하는 지문분류는 5부류 문제이기 때문에 총 5개의 OVA SVM을 학습하며, 샘플이 입력되면 최종적으로 그림 3에서의 o-svm값을 계산한다.

SVM을 학습한 후에는 이들의 평가순서를 결정하기 위해 그림 4에서와 같은 특이점과 의사용선 정보를 바탕으로 NB를 학습한다[5]. NB의 구조는 그림 2에서와 같이 각 클래스를 대표하는 노드 5개와 10개의 특징노드로 구성되며, 클래스와 특징 사이에만 확률적 인과관계가 존재한다. 중심점에 대한 삼각주나 의사용선 끝점의 상대적 위치와 거리를 계산하여 표 1과 같은 10개의 특징을 정의한다.

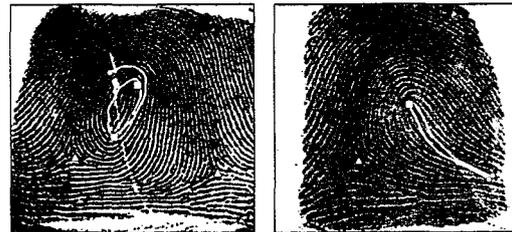


그림 4. 특이점과 의사용선

표 1. NB를 위한 특징 설계

| 특징 | 정의 | 상태 |
|------------------|------------------|--------------------|
| N_C, N_D | 추출된 중심점과 삼각주의 수 | 0, 1, 2 |
| D_{1L}, D_{2L} | 삼각주의 상대적 위치 | 0, 1, 2, 3, 4, 미존재 |
| R_{1L}, R_{2L} | 의사용선 끝점의 상대적 위치 | 0, 1, 2, 3, 4, 회전 |
| D_{1D}, D_{2D} | 중심점과 삼각주의 거리 | 1, 2, 3, 미존재 |
| R_{1D}, R_{2D} | 중심점과 의사용선 끝점의 거리 | 1, 2, 3, 회전 |

그림 2에서 NB의 각 노드의 조건부 확률은 n 개의 학습 데이터에 나타난 특징의 빈도를 계산하여 구하며, 입력된 샘플에 대해 10개의 특징들이 가지는 값을 증거변수로 사용하여 5개 클래스의 확률을 추론한다. 클래스의 확률은 수식 (3)을 이용하여 구하며, C 는 하나의 독립적인 클래스를 나타내고 F 는 특징 값을 나타낸다.

$$P(C|F_1, \dots, F_n) = \frac{P(C)P(F_1, \dots, F_n|C)}{P(F_1, \dots, F_n)} \quad (3)$$

분류는 최대 확률을 가지는 클래스를 선택하면 되기 때문에, 클래스와 상관없는 확률인 분모는 제외하여 수식 (4)와 같이 클래스의 확률을 계산한다. 이 확률값은 그림 3에서의 prob값에 해당한다.

$$\begin{aligned}
 & P(C)P(F_1, \dots, F_n|C) \\
 &= P(C)P(F_1|C)P(F_2|C) \dots P(F_n|C) \\
 &= P(C) \prod_{i=1}^n P(F_i|C)
 \end{aligned} \quad (4)$$

3. 실험 및 결과

3.1 실험환경

본 논문에서는 대표적인 지문분류 데이터인 NIST-4 데이터베이스로 제안하는 방법을 검증하였으며, Jain 등이 추출한 FingerCode를 이용하였다[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.

3.2 결과분석

RBF 커널 함수를 이용한 SVM은 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 SVM에서 가장 높은 값을 가지는 것의 부류를 선택하는 승자독식 전략의 경우에는 1.8%의 거부율에서 90.1%의 분류율을 획득하였다. 비교적 최근에 제안된 BKS나 DT의 경우 그리 높은 성능을 보이지는 않았으며, SVM과 NB의 결과를 단순 곱으로 결합한 경우 90.2%의 분류율을 획득하였다. 제안하는 방법은 90.8%로 표 2에서와 같이 다른 방법에 비해 높은 분류 성능을 획득하였다. 이는 복수의 SVM이 선택되는 중의적인 상황을 적절히 처리하였기 때문으로 해석된다. 표 3은 거부율 1.8%에서 제안하는 방법의 혼동 행렬을 보여준다.

표 2. 지문분류 결과

| 방법 | 분류정확률 (거부율 1.8%) |
|------------------|------------------|
| NB | 85.4% (거부율 0%) |
| SVM (승자독식) | 90.1% |
| SVM (ECC) | 90.1% |
| SVM (BKS) | 88.8% |
| SVM (DT) | 89.8% |
| SVM과 NB의 단순 곱 결합 | 90.2% |
| 제안하는 방법 | 90.8% |

표 3. 거부율 1.8%에서의 제안하는 방법의 혼동 행렬

| | W | R | L | A | T |
|---|-----|-----|-----|-----|-----|
| W | 373 | 10 | 10 | 0 | 0 |
| R | 4 | 374 | 0 | 6 | 15 |
| L | 5 | 0 | 377 | 8 | 9 |
| A | 0 | 6 | 4 | 365 | 40 |
| T | 1 | 8 | 15 | 39 | 295 |

본 논문에서는 제안하는 방법과 FingerCode나 특이점을 사용한 기존 연구[2,3,4]와의 성능을 비교하였다. 그림 4는 지문 영상 2,000장에 대한 분류 성능으로 거부율에 따른 분류율을 보여주며, 제안하는 방법이 대부분의 거부율에서 다른 방법에 비하여 높은 분류율을 획득하였다.

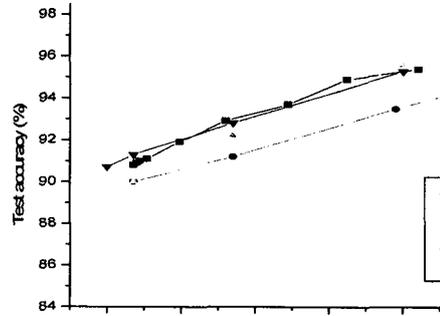


그림 5. 기존 연구와의 성능 비교

4. 결론

본 논문에서는 NB와 SVM을 효과적으로 결합하여 지문분류를 수행하는 방법을 제안하였다. 지문분류의 대표적 특징인 FingerCode를 SVM으로 학습하여 높은 분류성능을 확보하고, 특이점과 의사용선으로 학습된 NB로 OVA SVM의 분류모델을 적절히 구성하였다. 동시에 복수의 SVM이 선택되는 경우나 하나도 선택되지 않는 경우를 효과적으로 처리하여 NIST-4 데이터베이스에서 90.8%의 높은 분류성능을 획득하였다. 또한 기존의 지문분류 연구와의 비교를 통하여 제안하는 방법의 우수성을 확인하였다.

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] U.-K. Cho, J.-H. Hong, S.-B. Cho, "Fast fingerprint classification using the probabilistic integration of structural features," *Proc. of KCC*, vol. 32, no. 1, pp. 757-759, 2005.
- [6] C. Park and H. Park, "Fingerprint classification using fast Fourier transform and nonlinear discriminant analysis," *Pattern Recognition*, vol. 38, no. 4, pp. 495-503, 2005.