

구조적 특징의 확률적 결합을 이용한 빠른 지문분류

조웅근⁰, 홍진혁, 조성배
연세대학교 컴퓨터과학과
생체인식 연구센터
(bearroot⁰, hjinh, sbcho)⁰@sclab.yonsei.ac.kr

Fast Fingerprint Classification Using the Probabilistic Integration of Structural Features

Ung-Keun Cho⁰, Jin-Hyuk Hong, Sung-Bae Cho
Department of Computer Science, Yonsei University
Biometrics Engineering Research Center

요약

Henry의 지문분류법이 창안된 후, 지문분류에 대한 여러 가지 접근 방법이 연구되고 있다. 특이점에 의한 분류는 가장 많이 연구되고 있는 방법이지만, 지문영상의 품질에 민감하기 때문에 정확한 분류가 쉽지 않다. 의사 용선은 특이점과 더불어 지문을 분류하기 위한 특징으로, 특이점의 불완전함을 보완하는데 이용한다. 본 논문에서는 나이브 베이즈 분류기를 이용하여 특이점과 의사 용선 정보의 확률적인 분류 방법을 제안한다. NIST DB 4에 대해 제안하는 방법을 실험한 결과 5클래스 분류에 대해 85.4%의 분류율을 획득하였으며, 제안하는 방법이 신경망, 최근접 이웃에 의한 분류에 비해 더 빠르다는 것을 확인하였다.

1. 서론

자동 지문인식 시스템(Automatic Fingerprint Identification System, AFIS)은 많은 지문들 중에 개인의 지문과 동일한 지문을 찾기 위한 시스템으로, 비교해야 할 지문의 개수가 증가하면 정확도는 물론 속도도 떨어진다. 이를 해결하기 위해 지문영상들을 몇 개의 클래스로 분류하여 지문인식의 속도는 물론 인식의 정확도를 향상시키는 방법이 연구되고 있다. 1900년 Henry가 지문을 5가지 클래스로 분류한 이후, 지문분류를 위한 다양한 방법이 연구되었다. 지문분류의 대표적인 방법인 특이점을 이용한 분류는 다른 접근 방법들에 비해 분류율이 떨어지지만, 인간의 지식을 토대로 한 분류 방법이기 때문에 특이점을 잘 찾으면 정확한 분류가 가능하다. 하지만 일반적으로 지문 데이터는 영상의 품질이 떨어지기 때문에 정확한 특이점 추출에 한계가 있다. 다른 특징인 용선의 형태를 분석하는 방법도 함께 연구되고 있다. 의사 용선은 지문의 세선화 과정없이 구할 수 있기 때문에 빠른 추출이 가능한 반면 특이점과 마찬가지로 정확한 추출에는 한계가 있다[1].

정확한 분류를 위해서 이들 특징을 적절히 결합하는 것이 필요하다. 본 논문에서는 이러한 불확실한 특징들을 이용한 지문분류를 위해서 확률론을 기반으로 하는 나이브 베이즈(Naive Bayes) 분류기를 사용한다. 나이브 베이즈 분류기는 특징 집합과 클래스 집합과의 인과관계를 형성하여 확률적으로 추론하는 분류기이다. 나이브 베이즈 분류기의 확률은 학습에 의해 정해지며, 최근접 이웃(k-Nearest Neighbor), 신경망(Neural Network)등의 다른 방법에 비해 빠른 응답을 준다.

2. 관련 연구

2.1 특이점을 이용한 지문분류

지문에서의 특이점(singular points)은 지문분류에서 중요한 특징으로 사용되어 왔다. 특이점이란 용선의 흐름이 급격하게 변하는 점으로, 중심점(Core point)과 삼각주(Delta point)가 있으며 흔히 코어, 델타라고 부른다. 특이점을 추출하는 대표적인 방법으로 poincare 방법이 있다[1,2]. 지문영상으로부터 특이점

이 추출되면 특이점의 개수와 상호 위치에 따라 분류가 수행된다. 그러나 단순히 특이점만을 이용하는 분류는 지문영상의 품질에 많은 영향을 받기 때문에 보통 특이점과 더불어 다른 특징을 함께 이용하여 지문분류를 수행한다.

2.2 나이브 베이즈 분류기

나이브 베이즈 분류기는 클래스와 특징들의 인과관계를 간단한 구조로 표현한 것으로서, 추출된 특징들로 하여금 확률적인 추론으로 클래스를 분류한다[3, 4]. 나이브 베이즈 분류기는 각 클래스가 모든 특징의 원인이 되는 구조를 가진다. 각 특징은 증거노드로 사용되어 각 클래스의 확률을 계산하며, 분류기는 가장 큰 확률을 가진 클래스를 선택한다. 이 때 나이브 베이즈 분류기의 확률은 학습 데이터에 의해 계산되며, 실험 데이터에 의해 검증된다. 나이브 베이즈 분류기는 단순하고 빠른 응답을 주기 때문에 패턴 인식에서 많이 사용된다.

3. 제안하는 방법

3.1 특징 추출

보통 지문영상으로부터 정확한 특징을 추출하는 것은 쉽지 않기 때문에 본 논문에서는 대표적인 전처리 과정인 전경 배경 분리(Segmentation)와 영상 개선(Image Enhancement)을 이용하여 지문영상의 품질을 향상시킨 후에 특징을 추출한다[4].

용선의 방향성 정보는 특징을 추출하기 위한 것으로, 지문영상을 작은 크기의 블록으로 나누고 각 블록의 방향 정보를 나타낸다. 실제 이 과정을 거치면 방향성의 잡음이 많이 생기기 때문에 이웃 블록의 방향과 평균화를 시켜 보다 매끄러운 방향성 정보를 얻을 수 있는 방향성 정보 필터링(smoothing)을 수행한다[5].

본 논문에서는 지문분류를 위해 크게 두 가지의 특징을 추출한다. 먼저 방향성 정보를 이용한 가장 대표적인 특이점 추출 방법인 poincare 방법을 사용하여 특이점을 추출한다[1,2].

선택된 코어 중 중점과의 거리가 가장 가까운 점을 점 C라 할 때, 두 번째로 점 C에서 이어져있는 용선의 모양을 추출한다. 실제 용선의 모양을 직접 알아내는 것은 어려운 일이기 때

문에 방향성 정보를 이용하여 의사 용선을 추적한다[1]. 추적된 의사 용선은 그림 1과 같다. 그림 1(a)는 의사 용선이 오른쪽으로 향해있는 left loop의 경우를, 그림 1(b)는 의사 용선이 회전하는 whorl의 경우를 보여준다. 본 논문에서는 의사 용선의 끝점만을 추출하여 특징으로 사용한다.




그림 1. 특징 추출(□=코어, △=델타, ○=의사 용선 끝점)

본 논문에서는 먼저 특이점과 의사 용선의 끝점을 이용하여 규칙 기반 지문분류를 수행한다. 점 C에서의 각 위치의 상대적인 위치를 구한다. 어떤 점 P가 있을 때, 점 C에서의 2가지의 특징, 즉 상대적 위치와 거리에 대한 값을 구한다. 상대적 위치 값 L은 다음과 같은 식에 의하여 구한다.

$$1) C_y > P_y : L = \begin{cases} 0, & C_x > P_x \\ 4, & C_x \leq P_x \end{cases} \quad (1)$$

$$2) C_y \leq P_y : L = \begin{cases} 2, & \left| \frac{(C_y - P_y)}{(C_x - P_x)} \right| \geq 4.0 \\ 1, & C_x > P_x \\ 3, & C_x \leq P_x \end{cases} \quad (2)$$

점 C에서의 상대적 거리 값 D는 다음 식과 같이 구한다.

$$dis = (C_x - P_x)^2 + (C_y - P_y)^2 \quad (3)$$

$$D = \begin{cases} 1, & dis \leq 10 \\ 2, & 10 < dis \leq 20 \\ 3, & otherwise \end{cases} \quad (4)$$

이를 의미 구한 델타 D_1, D_2 , 의사 용선의 끝점 R_1, R_2 를 대입하여 코어와의 상대적인 위치와 거리의 값을 각각 구한다. 얻어지는 특징은 코어, 델타의 개수 (N_C, N_D), 델타(최대 2개)와 코어와의 상대적 위치 및 거리 값 ($D_{1L}, D_{1D}, D_{2L}, D_{2D}$), 의사 용선의 끝점과 코어와의 상대적 위치 및 거리 값 ($R_{1L}, R_{1D}, R_{2L}, R_{2D}$)으로, 이를 이용하여 지문을 분류한다. Whorl의 경우, 의사 용선이 회전 하는 경우가 있는데, 의사 용선의 끝점 R값은 또 다른 값으로, 회전이라고 정의 한다. D_1 과 D_2, R_1 과 R_2 는 각각 코어와의 상대적 위치 값에 따라 내림차순 정렬을 한다.

3.2 나이브 베이즈 분류기를 이용한 지문분류

지문영상 품질의 한계로 인해 완전한 특징 추출은 어렵다. 특이점과 의사 용선을 이용하여 규칙 기반의 지문분류를 할 경우 하나의 특징만 잘못 추출되어도 분류가 실패할 수 있다. 따라서 제안하는 방법은 불완전하게 추출된 특징들을 통계적으로 분석을 하여 확률에 의한 분류를 시도한다. 나이브 베이즈 방법으로 간단한 확률론에 의해 빠른 분류를 수행한다.

나이브 베이즈 분류기를 이용한 지문분류는 5개의 클래스(W, R, L, A, T)와 10개의 특징($N_C, N_D, D_{1L}, D_{1D}, D_{2L}, D_{2D}, R_{1L}, R_{1D}, R_{2L}, R_{2D}$)으로 구성되며, 15개의 노드간의 조건부 확

률은 학습 데이터에 의해 결정된다. 표 1은 본 논문에서 사용하는 특징의 의미와 가능한 상태를 보여준다.

표 1. 나이브 베이즈 분류기 구조의 노드 특징

특징	의미	가능한 상태
N_C, N_D	코어, 델타의 개수	0, 1, 2
D_{1L}, D_{1D}	델타의 위치	0, 1, 2,
R_{1L}, R_{1D}		
D_{2L}, D_{2D}	코어와 델타와의 거리	1, 2, 3
R_{2L}, R_{2D}		




그림 2. 지문분류를 위한 나이브 베이즈 분류기 구조

그림 2에서의 나이브 베이즈 구조로부터 각 노드의 조건부 확률을 n 개의 학습 데이터에 의해 구한다[3]. 나이브 베이즈 분류기에서 10개의 특징들이 가지는 값은 증거변수로 5개 클래스의 확률을 추론한다. 클래스의 확률은 식 (5)를 이용하여 구한다.

$$P(C|F_1, \dots, F_n) \quad (5)$$

이 때 C는 하나의 독립적인 클래스를 나타내고 F는 특징값을 나타낸다. 식 (5)는 베이즈 정리[4]로부터 식 (6)과 같이 계산된다.

$$P(C|F_1, \dots, F_n) = \frac{P(C)P(F_1|C)\dots P(F_n|C)}{P(F_1, \dots, F_n)} \quad (6)$$

분류기에서는 최대 확률값을 가지는 클래스를 선택하기만 하면 되기 때문에 클래스와 상관없이 특징들의 확률만을 구하는 분모를 제외한 분자의 값들만을 비교한다. 나이브 베이즈 구조에서 특징들은 서로 독립적이기 때문에 클래스의 확률을 식 (7)과 같이 간단하게 구한다.

$$\begin{aligned} P(C|F_1, \dots, F_n) &= P(C)P(F_1|C)P(F_2|C)\dots P(F_n|C) \\ &= P(C) \prod_{i=1}^n P(F_i|C) \end{aligned} \quad (7)$$

분류기는 10개의 특징을 이용하여 5개 클래스의 확률 중 가장 높은 확률 값을 가지는 클래스를 선택한다.

$$\text{arg max}_c P(C=c) = \prod_{i=1}^n P(F_i=f_i|C=c) \quad (8)$$

4. 실험 및 결과

4.1 실험 환경

본 논문에서는 대표적인 지문데이터인 NIST DB 4[6]를 사용하여 제안하는 방법을 검증한다. NIST DB 4는 2000쌍의 지문영상 즉, 4000개의 지문영상을 가지고 있으며, 5개의 클래스(W = whorl, R = right loop, L = left loop, A = arch, T = tented arch)로 분류되어 있다. 종종 지문영상의 애매모호함 때문에 하나의 클래스로 분류하기 힘든 경우가 있는데, tented arch의 경우 다른 클래스로 분류될 수 있는 영상이 많이 존재한다. 350쌍의 지문영상은 두 개의 레이블이 존재하여, 두 가지

의 클래스를 동시에 만족한다. 본 논문에서는 두 개의 레이블을 가지는 지문영상에 대해 하나의 클래스로만 분류한다면 잘 분류한 것으로 간주한다.

실험은 첫 번째 2000개의 학습 데이터와 두 번째 2000개의 실험 데이터로 나누어 수행하였다. 규칙 기반 지문분류와 같이 학습이 필요없는 경우 실험 데이터 2000개를 사용하였고, 나이브 베이즈 분류기의 확률 학습 등은 학습 데이터로, 분류 실험은 실험 데이터로 수행하였다.

4.2 실험 결과

표 2는 2000개의 실험 데이터를 그림 3의 규칙에 의한 지문분류를 한 결과를 보여주며, 규칙기반 지문분류는 1.1%의 거부율에 83.8%의 분류율을 얻었다. 표 3은 위에서 얻은 10개의 특징 값을 이용하여, 5개의 클래스를 나이브 베이즈 분류기로 분류한 결과로, 85.35%의 분류율을 보였다. 같은 특징을 사용한 최근접 이웃의 경우 $k=1$, $k=3$, $k=5$ 일 때, 평균 82.3%, 신경망을 사용하였을 때 10번의 실험에 대하여 평균 84.2%의 분류율을 각각 내었다. 표 4는 NIST DB 4에 대하여 실험한 결과를 보여주며, 실험을 통하여 제안한 방법 나이브 베이즈 분류기가 가장 높은 분류 성능을 보였다.

표 4. 기타 방법과의 분류율 비교

방법	규칙	1-NN	3-NN	5-NN	NN	NB
분류율(%)	83.8	82.3	80.4	82.1	84.2	85.35
거부율(%)	1.1	NA	NA	NA	NA	NA

학습 데이터가 많기 때문에 최근접 이웃의 경우 분류 시간이 27초로 가장 오래 걸렸으며, 5개의 은닉노드(hidden node)를 가진 신경망의 경우 500세대의 학습 시간만이 13초가 걸렸다. 그러나 나이브 베이즈 분류기의 경우 2000개의 데이터를 학습하는 시간과 2000개의 데이터를 분류하는 시간이 합해서 3초밖에 걸리지 않았다. 표 5는 각 방법의 4000개 데이터에 대한 학습과 분류에 걸리는 시간을 보여준다.

표 5. 기타 방법과의 속도 비교

방법	k-NN	NN	NB
시간(초)	27.782	13.047	3.313

5. 결론

지문분류의 대표적인 방법인 특이점을 이용한 분류는 올바른 특이점을 찾을 수 있다면 정확한 분류를 할 수 있다는 장점이 있다. 그러나 지문영상은 품질이 다소 떨어지는 경우가 있기에 정확한 추출이 불가능하다는 이유로 다른 접근 방법들에 비해 분류율이 떨어지기 마련이다. 본 논문에서는 특이점과 함께 의 사용성이라는 특징을 함께 사용하고, 나이브 베이즈 분류기를 이용한 지문분류 방법을 제안하였다. NIST DB 4를 이용한 실험으로 나이브 베이즈 분류기가 속도면에서 다른 분류기에 비해 훨씬 빠르다는 것을 확인하였다. 향후에는 특이점의 정확한 추출을 위한 지문영상 개선의 연구와 다른 분류기와의 결합방법에 대한 연구가 필요하다.

감사의 글

본 연구는 생체인식연구센터(KOSEF)에서 지원받았음.

참고 문헌

[1] Q. Zhang, and H. Yan, "Fingerprint classification based on extraction and analysis of singularities and pseudo ridges," *Pattern Recognition*, vol. 37, pp 2233-2243, 2004.
 [2] K. Karu, and A. Jain, "Fingerprint classification," *Pattern Recognition*, vol. 29, no. 3, pp 389-404, 1996.
 [3] Z. Wang, G. Webb, and F. Zheng, "Selective augmented Bayesian network classifiers based on rough set theory," *LNAI*, vol. 3056, pp. 319-328, 2004.
 [4] I. Rish, "An empirical study of the naive bayes classifier," *IJCAI-01 Workshop on Empirical Methods in Artificial Intelligence*, pp. 41-46, 2001.
 [5] L. Hong, Y. Wan, and A. Jain, "Fingerprint image enhancement: Algorithm and performance evaluation," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 20, no. 8, pp. 777-789, 1998.
 [6] C. Watson, and C. Wilson, *NIST Special Database 4. Fingerprint Database*. National Institute of Standard and Technology, 1992.

- 1) $N_C=2$ 이면 : W
- 2) $N_C=0$ 이고 $N_D=0$ 이면 : A
- 3) R_1 혹은 R_2 가 회전하면 : W
- 4) $N_C=1$ 이고 $N_D=1$ 일 때
 - ㄱ. $D_{1L}=1$: R
 - ㄴ. $D_{1L}=2$: L
 - ㄷ. $D_{1L}=3$: T
- 5) 코어, 델타의 개수, 위치만으로 알 수 없는 경우 의사용선의 끝점을 사용한다.
 - ㄱ. $R_{2L}=1$: L
 - ㄴ. $R_{1L}=3$: R
 - ㄷ. $R_{1L}=1$ 이고 $R_{1L}=3$: T
- 6) 그 외 : 거부

그림 3. 지문분류의 간단한 규칙

표 2. 규칙기반 지문분류

실제클래스	결과					거부
	W	R	L	A	T	
W	366	16	9	0	3	4
R	19	352	3	4	37	0
L	17	1	372	6	31	2
A	11	4	14	373	21	11
T	21	12	31	60	195	5

표 3. 나이브 베이즈 분류기를 이용한 지문분류

실제클래스	결과				
	W	R	L	A	T
W	370	15	12	0	0
R	10	378	16	4	18
L	14	1	388	6	18
A	6	15	21	377	15
T	9	16	36	61	194