

ANMM(Average Neighborhood Margin Maximization)에 기반한 피부색과 비피부색 분리력 향상 기법

반유석, *이상윤
연세대학교 전기전자공학부
van@yonsei.ac.kr, *syleee@yonsei.ac.kr

Skin and non-skin color separability enhancement
based on Average Neighborhood Margin Maximization

Yuseok Ban *Sangyoun Lee
Yonsei University *Yonsei University

요 약

본 논문에서는 지역적 학습 방법을 활용하는 Average Neighborhood Margin Maximization(ANMM)에 기반하여 피부색과 비피부색 영역을 분리하는 이진 분류의 통계적 접근법을 제안한다. Fisher Linear Discriminant(FLD)와 Average Neighborhood Margin Maximization(ANMM)의 피부색과 비피부색 클래스 내 분산 대비 클래스 간 분산의 비교를 통해 두 클래스 간 분리력 변화를 확인한다. 교사(Supervised) 이진 분류 문제에 대하여 Small sample size(SSS) 문제, 가우시안 분포 가정의 문제, 최대 추출 가능 특징 수 제한 문제를 해결함과 동시에, 지역적 특성 학습 방법의 도입을 통해 피부색과 비피부색 간 분리력을 향상시킨다.

1. 서론

최근 국내외에서는 디지털 기술 발전에 따른 디지털 방송 방식의 첨단 기술 개발 및 표준화가 진행되고 있는 추세다. 향후 디지털 방송은 다채널화, 고품질화, 멀티미디어화, 다기능화된 방송 환경 조성을 목표로 하고 있다. 대화형 및 실감형 방송 기술 중 콘텐츠 기반 검색 기술은 얼굴 검출, 얼굴 인식 등 다양한 기술이 복합되어 있다. 방송 콘텐츠의 중요한 정보인 인물에 대한 정보는 얼굴의 특징을 추출함으로써 취득할 수 있다. 피부 색상 정보를 활용한 얼굴 검출 및 얼굴 인식은 효과적인 디지털 방송 콘텐츠 검색을 가능케 한다.

기존의 FLD 를 피부색과 비피부색 이진 분류에 적용하면, 1)Small sample size(SSS)문제, 2)동일 분산을 갖는 Gaussian 분포의 가정, 3)C-1 개의 최대 추출 가능 특징 수 (단, C 는 클래스 수), 4)전역적인 선형 구조만을 반영하는 문제가 발생하게 된다. 본 논문에서는 지역적 학습 방법에 기반한 ANMM)을 피부색과 비피부색 이진 분류에 적용하여 기존의 FLD 의 문제점들을 극복함과 동시에, 피부색과 비피부색의 클래스 내 분산 대비 클래스 간 분산을 향상시키는 방법을 제안한다.

2. FLD 와 ANMM

2.1 Fisher Linear Discriminant(FLD)

FLD 는 부공간으로 사영된 데이터가 가장 잘 분리될 수

있는 사영 방향을 제시하는 교사방법이다. 따라서 클래스 간 분산을 최대화함과 동시에 클래스 내 분산을 최소화하는 변환행렬을 찾는 것이 목표이다. 두 클래스가 최대한으로 분리되는 변환행렬 w 는 특정 상수 λ 에 대하여 클래스 간 분산 S_B 과 클래스 내 분산 S_w 로 구성된 $S_B w = \lambda S_w w$ 와 같은 일반화된 고유치 문제의 해로써 정의된다[5].

FLD 는 몇 가지 한계를 갖고 있다. 첫째, Small sample size(SSS) 문제가 발생한다. 둘째, 동일한 크기의 분산을 갖는 가우시안 분포의 데이터에 최적화 되어있다. 셋째, C 개의 클래스에 대해 최대 C-1 개까지만 특징을 추출할 수 있다. 넷째, 선형 전역 구조만을 반영한다.

2.2 Average Neighborhood Margin Maximization(ANMM)

ANMM 은 부공간으로 사영된 데이터가 클래스 내 유사성과 클래스 간 분리성을 모두 큰 값으로 갖는 변환행렬을 찾는 교사방법이다. FLD 또는 FLD 의 변형 형태들과 같은 대부분의 기존 연구는 전역적인 접근 방법으로 사영 부공간을 찾는 것에 반해, ANMM 은 전역적이 아닌 지역적인 접근 방법을 사용한다는 점이 특징이다. 전체 데이터 집합에 대해 높은 분리력을 갖는 부공간을 전역적으로 찾기는 쉽지 않다[3]. 따라서 지역적인 접근으로 분리력의 향상을 기대할 수 있다[2].

평균이웃마진은 기준 데이터와 동종이웃 간 거리의 평균과 이종이웃 간 거리의 평균의 차이를 의미하는데, 평균이웃마진의 최대화는 기준 데이터와 동종이웃은 가깝게 당기고, 이종이웃은 멀리 미는 양상의 사영 공간

을 형성한다. 따라서 평균이웃마진의 최대화는 곧 전체 데이터에 대한 이진분류의 분리력의 최대화로 이어진다. (단, 동종이웃은 같은 클래스의 데이터 집합, 이종이웃은 다른 클래스의 데이터 집합을 의미한다.)




그림.1 ANMM의 직관적 표현: (왼쪽)원본 공간 (오른쪽) ANMM 사영 / $x(x_i)$, 검정색(x_i 의 동종이웃), 회색(x_i 의 이종이웃)

위와 같은 조건의 변환행렬 w 는 식(5)에서와 같이 Scatterness 행렬과 Compactness 행렬의 차이, $S-C$ 의 상위 l 개의 고유치에 상응하는 l 개의 고유벡터로 구성되는 특징을 Lagrangian 방법을 통해 할당하여 구한다.

Ky Fan theorem에 의해 l 개의 고유치는 $S-C$ 행렬의 음수가 아닌 고유치에 해당한다[1] (F. Wang et al.).

$$w^* = \arg \max_{w_k} \sum_{k=1}^l w_k^T (S-C) w_k \quad s.t. \quad w_k^T w_k = 1 \quad \text{식(5)}$$

3. 실험

3.1 실험 환경

CMU PIE (68명) 얼굴영상과 IMM(37명) 얼굴영상 포맷을 각각 160x120 JPG로 변환하여 사용하고, 학습 조건으로써 다양한 인종(피부색 변화)과 조명 변화가 고려사항이다. 피부색 및 비피부색 영역에 대한 정보는 교사방법을 위해 각 클래스 단위로 모든 좌표를 수동으로 저장한다. 이종이웃 수와 동종이웃 수는 각각 10,20,40개로 조정한다..

3.2 평가 방법

피부색을 표현함에 있어서 취득한 RGB 색상 공간을 YCbCr 색상 공간 상으로 변환하여 Cb 채널과 Cr 채널을 사용하여 나타내는 것이 적합하다[4]. 따라서 두 채널에 대해 다음과 같은 평가 방법을 사용한다.

$$\frac{\text{동종이웃의 평균}(\mu_{c,b}, \mu_{c,r}) \text{과 이종이웃의 평균}(\mu_{e,b}, \mu_{e,r}) \text{ 사이 거리}}{\text{동종이웃의 분산} \tilde{S}_o \text{과 이종이웃의 분산} \tilde{S}_e \text{의 총합}}$$

3.3 실험 결과

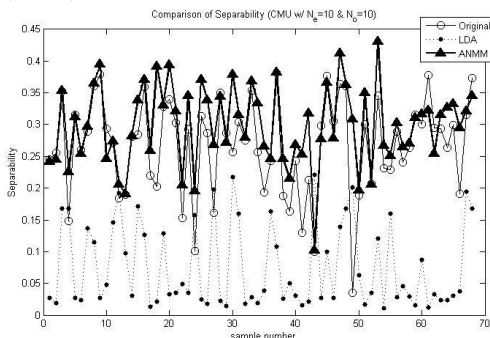


그림.2 (CMU PIE) x 축: 68개체의 번호, y 축: 분리력 / 점선(원본영상), 원(FLD), 세모(ANMM), 별(비선형 ANMM) / 동종이웃=10, 이종이웃=10




그림.3 (IMM 11번 개체) 피부색 영역과 비피부색 영역 분포도 / (a)원본, (b)FLD, (c)ANMM / 검은색(피부), 회색(비피부)

4. 결론

본 논문에서는 지역적 학습 방법에 기반한 ANMM 피부색과 비피부색의 이진 분류를 통해 FLD가 갖는 1)SSS 문제를 역행렬을 사용하지 않으므로써 해결하고, 2)클래스 분포의 유형을 가정하지 않으므로써 동일 분산의 가우시안 분포 가정을 극복하고, 3)C-1개로 최대 추출 가능 특징 수를 제한하지 않으며, 4)전역적 선형성이 아닌 지역적 선형성의 도입으로 FLD보다 피부색과 비피부색 클래스 내 분산 대비 클래스 간 분산, 즉 클래스 간 분리력을 향상시켰다. 실제로 피부색과 비피부색 영역이 겹친 분포의 형성 가능성이 높고, 영상에 따라 그 분포의 방향과 정도에도 차이가 존재하기 때문에 지역적 학습 방법의 도입이 긍정적인 효과가 있었다. CMU PIE DB와 IMM DB에서 모두 ANMM을 통해 원본 분포 대비 분리력이 각각 10.31%, 9.65% 향상됨을 확인했다.

향후에는 ANMM이 얼굴검출, 감시시스템 등에 활용하기에 적합하도록, 분리력의 극대화를 위한 사영 부공간을 다룸에 있어서 커널에 기반한 단순화된 변환행렬 계산 방법과 비선형성의 도입에 기반한 연구가 필요할 것이다.

참고 문헌

[1] F. Wang et al., MarginFace: A novel face recognition method by average neighborhood margin maximization, Pattern Recognition 42, 2009.
 [2] K.Q. Weinberger, J. Blitzer, L.K. Saul, Distance metric learning for large margin nearest neighbor classification, Advances in Neural Information Processing Systems 18, 2006.
 [3] V.N. Vapnik, The Nature of Statistical Learning Theory, Springer, Berlin, 1995.
 [4] Rein-Lien Hsu et al., Face Detection in Color Images, IEEE Transactions on Pattern Analysis and Machine Learning, Vol. 24, NO. 5, May 2002.
 [5] Aleix M. Martinez et al., PCA versus LDA, IEEE Transactions on Pattern Analysis and Machine Learning, VOL.23, NO.2, February 2001.

감사의 글

이 논문은 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2011-0016302)