

방향성 프로파일을 적용한 능동형태 모델

김 정 엽[†]

Active Shape Model with Directional Profile

Jeong Yeop Kim[†]

ABSTRACT

Active shape model is widely used in the field of image processing especially on arbitrary meaningful shape extraction from single gray level image. Cootes et. al. showed efficient detection of variable shape from image by using covariance and mean shape from learning. There are two stages of learning and testing. Hahn applied enhanced shape alignment method rather than using Cootes's rotation and scale scheme. Hahn did not modified the profile itself. In this paper, the method using directional one dimensional profile is proposed to enhance Cootes's one dimensional profile and the shape alignment algorithm of Hahn is combined. The performance of the proposed method was superior to Cootes's and Hahn's. Average landmark estimation error for each image was 27.72 pixels and 39.46 for Cootes's and 33.73 for Hahn's each.

Key words: Active Shape Model, Face Alignment, Color Features

1. 서 론

능동형태 모델(Active shape model; ASM)은 입력영상으로부터 임의의 영역을 추출하기 위해 제안된 방법이다. 추출하고자 하는 형태가 고정되어 있지 않고, 일정한 변화폭을 가지는 가변적인 경우에는 특징치를 기반으로 하여, 해당영역을 효과적으로 추출하기 어렵다. Cootes 등[1]이 제안한 방법은 공분산(covariance)의 값으로 표현된 미리 결정되어 있는 변화 범위를 입력으로 활용하여 가변적인 형태의 추출 성능이 향상됨을 보였다. 가변적인 형태를 검출하기 위한 방법은 스네이크(active contour model) 방법[2]이 있지만, 상황에 따라 학습에 사용한 형태와 전혀 다른 결과를 얻게 되는 경우도 있다. 이는 능동형태 모델에서 도입한 유효입력의 가변적인 범위를 지정하지 않은 결과이다.

일반적인 능동형태 모델은 크게 학습(training)과 시험(testing)의 2개 단계로 구성된다. 학습단계에서는 입력영상으로부터 적절한 데이터를 대상으로 하여 대표적인 특성을 추출하여 사전 정보로 기록하는 것이고, 시험단계는 누적 정리된 입력영상들의 특성을 활용하여 미지의 영상으로부터 특성정보를 결정하고 추출하는 것이다. 본 논문에서는 학습과 시험단계에 대하여 얼굴영상을 다루는 예를 기준으로 적용하고자 한다. 학습단계에서 사용되는 대표적인 특성을 예로 들면, 얼굴의 주요 특징 점들의 집합으로 표현되는 랜드마크(landmarks)인데, 통상 2차원 공간에서 가로와 세로의 2차원 좌표로 표현되는 벡터이다. 랜드마크는 얼굴 윤곽과, 눈, 코, 입 등을 나타내는 주요한 기준점들의 집합이다. 학습을 위한 랜드마크 정보는 사람이 수작업으로 직접 추출하여 기록한 것이 주로 사용되고, 성능검증의 기준으로 활용된다.

※ Corresponding Author : Jeong Yeop Kim, Address: (48015) 99 Pilbong-gil Haeundae-gu, Busan, Korea, TEL : +82-51-540-7105, FAX : +82-51-540-7280, E-mail : neocopy@ysu.ac.kr
Receipt date : Sep. 16, 2017, Revision date : Oct. 31, 2017

Approval date : Nov. 1, 2017

[†] School of Undeclared Majors, Youngsan University

※ This work was supported by a 2017 research grant from Youngsan University, Republic of Korea.

학습단계의 주요 결과물은 입력한 영상들의 집합으로부터 추출되는 대표적인 평균 랜드마크 정보와 입력영상의 변화에 따라 동일 랜드마크에 해당하는 각 좌표들의 변화 폭을 공분산 값으로 나타낸 것, 랜드마크 주변 화소의 특징 값 변화 정보 등이다. 이 3가지 정보는 저장되어 얼굴 주요 좌표의 평균적인 값과 좌표의 변화 폭, 주변 화소의 특징 변화 정도를 기록한 것으로, 시험단계에서 기준 데이터로 쓰여 진다. 능동형태 모델의 시험단계에서는 기록된 평균 랜드마크 좌표를 미지의 입력영상에 투영한 다음, 랜드마크 좌표를 중심으로 주변을 탐색하여, 가장 변화 형태에 충실한 지점을 찾아낸다. 이 결정 과정에서 랜드마크들의 좌표 변화 폭에 해당하는 공분산 정보와 주변 화소의 특징 변화 정도가 이용된다. 즉, 평균 랜드마크 좌표 주변을 탐색하여 좌표 값의 변화 폭과 주변 영역 화소의 특징 값 변화 정보가 가장 일치하는 지점을 찾아내는 일련의 최적화 과정으로 볼 수 있다. 시험단계를 적절히 사용하기 위해서는 임의의 입력영상으로부터 얼굴영역을 추출하는 방법이 선행되어야 하는데, 대부분의 연구에서는 Viola와 Jones의 방법[2]이 사용되고 있다.

능동 외관 모델(Active appearance model; AAM)은 상기 ASM의 단점을 보완하기 위해 제안된 모델이며, 주요 랜드마크 주변의 텍스처(texture) 정보의 활용이 추가되었다. AAM은 모델링과 처리시간이 ASM에 비해 긴 것이 단점이다. 그러므로 본 논문에서는 계산 량 대비 성능이 좋은 편인 ASM을 선택하여 성능을 개선하고자 한다. ASM의 주요한 단점[3]을 살펴보면,

1) 단일한 형태로 모델링하는 경우, 복잡한 구성을 가지는 물체에 대응하기 어렵다. 대상의 전체적인 형태를 표현하는 것은 가능하지만 일부분을 표현하거나 추출하는 것은 쉽지 않은 문제이다.

2) 랜드마크 주변의 국부적인(local) 특성을 이용하여 분석하므로, 전체적인 형태의 추출이 효율적으로 이루어지지 않고, 상당히 다른 형태를 추출하는 경우가 있다.

3) 다양한 형태를 수용하기 위해서는 대응량의 학습 데이터가 필요하다. 학습단계에서 얻어지는 평균적인 형태가 폭 넓게 확보되지 않으면, 시험단계에서 적절한 형태가 추출되기 어렵다.

4) 학습단계에서 구해진 평균적인 형태를 시험단

계에 적용하는 경우, 초기 위치의 지정이 어렵다. 시험단계에서 유효한 정보의 추출은 평균적인 형태의 랜드마크를 중심으로 주변을 탐색하기 때문에, 초기 랜드마크의 위치가 적절하게 설정되지 않으면 효율적인 탐색이 이루어지지 않는다. 랜드마크의 초기 위치의 변동에 따른 유효한 정보 추출 성능의 변화가 크기 때문에 ASM의 대표적인 단점으로 간주된다.

5) 랜드마크 주변의 국부적인 영역의 특성을 모델링할 때, 다양한 관점에서 고려하기 어렵고, 대부분의 경우는 밝기 값(gray level)의 변화 정보를 이용하는

6) 랜드마크 주변의 영역을 탐색하여 특성이 일치하는 지점을 추출할 때 사용되는 도구가 유클리드 거리(Euclidean distance) 또는 마할라노비스 거리(Mahalanobis distance) 등으로 제한되어 있다. 유클리드 거리보다는 마할라노비스 거리가 더욱 광범위하게 사용되고 있으며, 판정 대상 지점들의 분포 패턴을 고려하기 때문에 더욱 효율적인 것으로 간주되지만, 다양한 판정 도구의 개발이 필요하다.

본 논문에서는 상기 ASM의 문제점 중, 두 번째 언급된 국부적인 특성의 이용에 관하여 중점적으로 고찰하고자 한다. 최초로 제안된 ASM은 1차원 프로파일을 기준으로 처리하는 방식이다. 고려 대상인 랜드마크 좌표를 기준으로 경계선 정보를 추출하고, 경계선에 수직인 방향으로 직선상에 존재하는 좌표들을 대상으로 밝기 값의 변화분만을 기록하였다. 이와 같은 방법은 방향성에 따른 결과의 가변성이 클 수 있으므로, 랜드마크 좌표를 기준으로 2차원 프로파일을 이용하는 방법이 제안되었다[4]. 2차원 프로파일을 사용하는 경우, 정확도가 증가한다는 장점이 있지만 계산 시간이 상당히 증가한다는 문제점이 있다. 계산 량을 줄이기 위해 공분산 행렬을 절단(trimming)하는 방법들도 제안되었지만 원래의 2차원 프로파일에 비하여 계산 량이 크게 줄어들지는 않는다. 본 논문에서는 랜드마크 주변의 2차원 공간 밝기 값의 변화 정보를 이용하는 2차원 프로파일의 장점과 계산 량이 상대적으로 적은 1차원 프로파일의 장점을 활용하기 위하여 방향성 프로파일을 이용하는 ASM을 제안한다. 제안한 방법은 학습단계에서 가로, 세로, 대각선의 4개 방향에 대한 밝기 값의 변화를 계산하고, 방향에 따른 변화 패턴을 학습 데이터로 기록한다. 시험단계에서는 해당 랜드마크 별로 기

록된 방향 정보와 변화 패턴을 이용하여 최소의 오차를 가지는 대상 좌표를 추출한다. 제안한 방법은 기존의 1차원 프로파일보다 정확도가 높고, 계산시간은 유사한 장점을 가진다. 2장에서는 기존의 연구방법인 1차원 프로파일, 2차원 프로파일에 대한 내용을 요약하고, 3장에서는 제안한 방법의 내용을 구체적으로 설명한다. 4장에서는 성능평가를 포함한 실험 결과를 정리하고 분석한다.

2. 기존의 연구방법

2.1 1차원 프로파일 ASM

Cootes 등[1]이 제안한 1차원 프로파일을 이용하는 방법은 공분산(covariance)의 값으로 표현된 미리 결정되어 있는 변화 범위를 입력으로 활용하여 가변적인 형태의 랜드마크를 추출하는 것이다. Cootes의 방법은 학습과 시험의 2개 단계로 구성된다. 학습단계에서는 입력 영상의 집합과 함께, 미리 추출된 얼굴영역의 주요 랜드마크 좌표를 이용한다. 학습을 위해서는 입력 영상 집합 중에서 한 장의 영상으로부터 모든 랜드마크 좌표를 읽어 들인 다음, 각 랜드마크 좌표의 주변 영역을 탐색하여 밝기 값의 변화 패턴을 프로파일로 계산하게 된다. 이 후, 각각의 입력 영상에 대하여 모두 동일한 방식으로 프로파일 계산을 수행하고, 최종적인 학습 결과물은 미리 확보된 랜드마크 좌표의 평균값을 이용하여 구하는 랜드마크 평균 벡터인 L_m 과 각각의 입력영상으로부터 구한 밝기 값의 변화 패턴인 프로파일의 평균 x_m , 누적한 프로파일로부터 구하는 공분산 S_g 이다. 랜드마크의 평균 L_m 을 계산하기 위하여, 먼저 i 번째 형태에서 추출한 N 개의 랜드마크 점들의 벡터 L_i 를 식(1)과 같이 정의한다. 여기서 (x,y) 는 2차원 공간상의 랜드마크 점의 실제 좌표를 의미한다.

$$L_i = \begin{bmatrix} x_{i0} & y_{i0} \\ x_{i1} & y_{i1} \\ x_{i2} & y_{i2} \\ \vdots & \vdots \\ x_{iN} & y_{iN} \end{bmatrix} \quad (1)$$

이와 같이 구해진 랜드마크 벡터를 이용하여 평균 벡터인 L_m 은 식(2)와 같이 구할 수 있다. 여기서 K 는 학습에 참가하는 전체 영상의 수이다.

$$L_m = \frac{1}{K} \sum_{i=1}^K L_i \quad (2)$$

프로파일의 평균 x_m 를 구하기 위해서 먼저, 각 영상에서 랜드마크 좌표점을 기준으로 하여 Fig. 2 a)의 1차원 직선 형태의 부분에 대한 밝기 값의 차분 벡터인 $g_{i,L}$ 을 식(3)과 같이 구한다. 여기서 $G_{i,L,m}$ 은 학습중인 i 번째 영상의 L 번째 랜드마크에 해당하는 밝기 벡터의 m 번째 화소 밝기 값을 의미한다.

$$g_{i,L} = [G_{i,L,1} - G_{i,L,0} \quad G_{i,L,2} - G_{i,L,1} \quad G_{i,L,3} - G_{i,L,2} \dots G_{i,L,m} - G_{i,L,m-1}]' \quad (3)$$

프로파일의 평균 x_m 은 계산된 $g_{i,L}$ 을 이용하여 전체 영상 집합에 대하여 식(4),(5)와 같이 계산할 수 있다.

$$\bar{g}_L = \frac{1}{K} \sum_{i=1}^K g_{i,L} \quad (4)$$

$$x_m = [\bar{g}_1 \quad \bar{g}_2 \quad \bar{g}_3 \dots \bar{g}_L]' \quad (5)$$

공분산 S_g 는 식(6)과 같이 계산된다. 여기서 L_i^* 은 i 번째 영상의 형태정렬 후의 형태벡터이다.

$$S_g = \frac{1}{K} \sum_{i=1}^K (L_i^* - L_m)(L_i^* - L_m)' \quad (6)$$

이상의 학습단계를 거치고 나면 입력한 영상 집합에 대한 평균적인 얼굴의 대표적 특징으로 볼 수 있는 랜드마크 좌표 평균 값, 랜드마크 주변의 밝기 값 변화 패턴에 대한 평균과 변화 폭을 공분산의 형태로 얻을 수 있다. 시험단계에서는 임의의 학습에 참여하지 않은 영상을 입력으로 하고, 학습결과인 평균 랜드마크 좌표, 프로파일 평균, 공분산 값을 이용한다. 가장 먼저, 평균 랜드마크 좌표로 구성된 얼굴의 형태인 L_m 을 입력영상에 투영하여 얼굴 특징의 초기 위치를 설정한다. 초기 위치의 설정에 따른 성능의 차이가 발생할 수 있으며, 대부분의 경우는 얼굴 폭에 해당하는 랜드마크 좌표를 이용하여 초기 위치를 설정한다. 설정된 초기 위치 각각의 랜드마크 좌표를 중심으로 주변 영역의 프로파일 x 에 대하여 탐색을 실시한다. 이 때 사용되는 주변 영역의 형태는 1차원 직선의 모양을 가지므로 1차원 프로파일이라고 한다. 밝기 값의 변화 패턴인 프로파일에 대하여 공분산을 고려한 계산을 식(7)과 같이 구한다. $f(x)$ 로 정의된 마할라노비스 거리 중 최소 값을 가지는 지점을 구하여 최소 오차 지점으로 정의하고, 해당 지점을 입력영상에 대한 랜드마크 추정 결과로 간주한다.

$$f(x) = (x - x_m)' S_g^{-1} (x - x_m) \quad (7)$$

일정한 범위의 1차원 프로파일에 대하여 최소 오차의 변화를 계산한 다음 변화가 없으면 해당 지점을 최종 결과로 정의한다. 프로파일에 대한 변화가 존재하는 경우는 전체 최소(global minima)가 아닌 국부 최소(local minima)인 경우이므로 일정 범위에 대하여 계산을 반복 수행한 다음 최종 결과를 얻는다. 얼굴영역을 구성하는 모든 랜드마크 좌표에 대하여 동일한 방식의 계산을 적용하여 최종적인 얼굴영역을 구성하는 랜드마크 좌표 점들을 추출한다.

2.2 2차원 프로파일 ASM

2차원 프로파일은 Milborrow[4]가 처음 도입하였으며, 1차원 프로파일과 2차원 프로파일을 복합적으로 사용하였다. 얼굴의 외곽선과 눈, 코 등의 부분에는 2차원 프로파일을 사용하고, 나머지 부분은 1차원 프로파일을 적용하였다. 계산 량 감소와 1차원 프로파일로 검출하기 어려운 변화가 민감한 부분의 성능을 개선하기 위한 방법이며, Seshadri[5] 등은 모든 랜드마크에 대하여 2차원 프로파일만을 적용한 방법을 제안하기도 하였다. 2.1절의 1차원 프로파일을 이용하는 방법의 처리과정과 동일하며, 프로파일의 형태가 1차원 직선에서 2차원 윈도우(window)로 변경된 것이다. 성능은 1차원 프로파일 방식에 비하여 우수하지만 계산 량이 많다는 단점을 가진다. 2차원 프로파일 방식에서는 2차원 행렬을 1차원 벡터의 형태로 변환하여, 실질적인 계산에서는 1차원 벡터 형태의 프로파일을 사용하고, 공분산을 구할 때도 1차원 벡터 형태의 프로파일을 누적하여 계산하므로 1차원 프로파일 방식과 동일하다. 본 논문에서는 계산 량의 부담이 적은 1차원 프로파일 방식의 성능을 개선하고자 한다.

2.3 형태정렬을 개선한 ASM

Hahn[6]의 방법은 Mohammad[3] 등이 제안한 기존의 자유도 4의 형태정렬 대신 자유도 6의 형태정렬과 두 눈과 입의 중점의 3개 지점을 이용하여 형태정렬의 변수를 계산하는 방법을 기반으로 한다. Mohammad 등의 방법은 3개 지점이 확보되어야 정확한 계산을 할 수 있는 단점을 가진다. 예를 들면, 안경을 쓰거나, 한쪽 눈이 가려지는 경우 등은 해를 구할 수 없다. Hahn은 형태정렬 변수를 계산할 때 3개 지점

을 이용하는 대신 전체 랜드마크 집합을 모두 이용하여 해를 구하는 방법을 제안하여 Mohammad 등의 경우보다 성능이 우수함을 보였다. Hahn은 식(8)의 오차함수를 정의하고, 식(9)와 같은 기존의 자유도 4의 형태정렬을 변형하여 자유도 6의 형태정렬인 식(10)을 구성하고, 오차함수인 식(11)을 계산하여 개선된 형태정렬을 구현하였다.

$$E = (x_i - x_j)' W(x_i - x_j) \tag{8}$$

$$\begin{bmatrix} x_{jk}^* \\ y_{jk}^* \end{bmatrix} = \begin{bmatrix} s_j \cos \theta_j & -s_j \sin \theta_j \\ s_j \sin \theta_j & s_j \cos \theta_j \end{bmatrix} \begin{bmatrix} x_{jk} \\ y_{jk} \end{bmatrix} \tag{9}$$

여기서, x_i 는 변형 후에 구하고자 하는 목표 형태이고, x_j 는 변형을 적용하는 대상 형태이다.

$$\begin{bmatrix} x_{jk}^* \\ y_{jk}^* \\ 1 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & t_x \\ a_{21} & a_{22} & t_y \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} x_{jk} \\ y_{jk} \\ 1 \end{bmatrix} \tag{10}$$

$$E = \sum_{k=0}^{n-1} w_k (x_{ik} - a_{11} x_{jk} - a_{12} y_{jk} - t_x)^2 + \sum_{k=0}^{n-1} w_k (y_{ik} - a_{21} x_{jk} - a_{22} y_{jk} - t_y)^2 \tag{11}$$

3. 방향성 프로파일과 형태정렬을 이용한 ASM의 제안

이 장에서는 1차원 프로파일의 정확도를 개선하기 위하여 방향성 프로파일을 적용하는 ASM 방법을 제안한다. 얼굴영역에 대한 주요 특징인 랜드마크 좌표의 추출성능을 기준으로, 1차원 프로파일 기본형, 형태정렬을 개선한 Hahn의 방법 등과 제안한 방법의 성능을 비교한다. 또한, Hahn의 방법과 방향성 프로파일을 결합하여 형태정렬과 프로파일을 모두 개선한 방법을 제안하였다.

3.1 학습 단계

학습을 위해 사용하는 절차는 기존 방법과 유사하며 다음 Fig. 1에 나타내었다.

제안하는 방향성 프로파일은 사용하는 프로파일의 형태를 기존의 Fig.2 (a)와 같은 직선 모양 대신에 Fig. 2(b)와 같이 가로, 세로, 대각선으로 구성되는 4개의 방향으로 직선 형태를 구성하는 것이다. 학습 단계에서 계산되는 평균 프로파일 벡터 x_{mT} 는 방향별로 각각 계산되고 식(14)와 같다. 모든 학습 영상에 대하여 방향별로 평균 프로파일 벡터와 변화의 척도

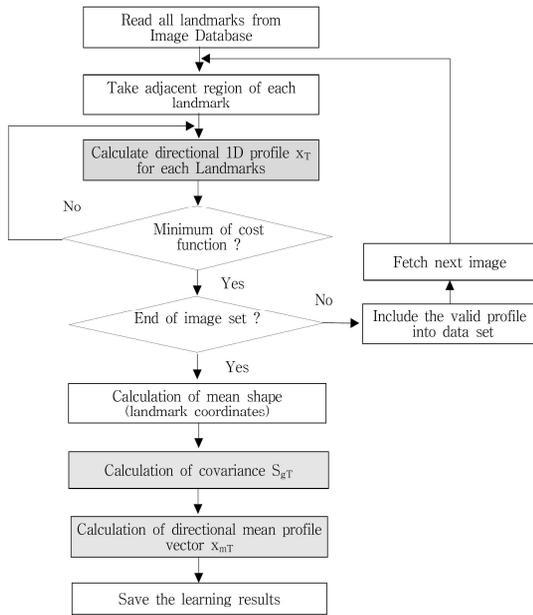


Fig. 1. Flowchart of proposed learning step.

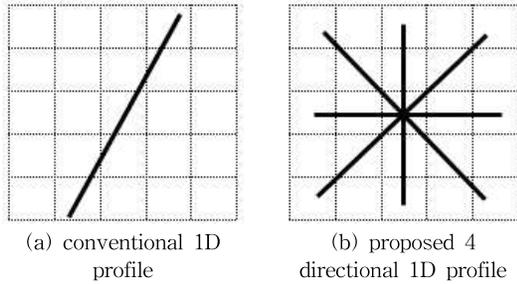


Fig. 2. Proposed directional 1D profile.

인 고유벡터 및 고유치를 구할 수 있다.

$$g_{i,L,T} = [G_{i,L1,T} - G_{i,L0,T} \quad G_{i,L2,T} - G_{i,L1,T} \quad \dots \quad G_{i,Lm,T} - G_{i,Lm-1,T}]' \quad (12)$$

$$\overline{g_{L,T}} = \frac{1}{K} \sum_{i=1}^K g_{i,L,T} \quad (13)$$

$$x_{m,T} = [\overline{g_{1,T}} \quad \overline{g_{2,T}} \quad \overline{g_{3,T}} \quad \dots \quad \overline{g_{L,T}}]' \quad (14)$$

3.2 시험 단계

기존 방법과의 차이점은 학습단계에서 제안한 방향성 프로파일 계산부분이다. 시험단계에서 사용되는 프로파일의 계산 및 최소오차 지점 결정과정이 방향성을 고려하여 수정되었고, 처리과정은 Fig. 3에 나타내었다.

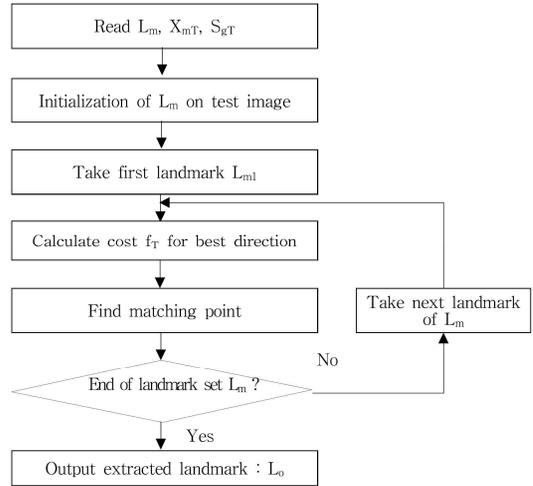


Fig. 3. Flowchart of proposed test step.

최소오차 지점 결정을 위해서는 랜드마크 좌표지에서 각 방향별로 프로파일 x_T 를 식(16)을 통하여 구한다.

$$g_{L,T} = [G_{L1,T} - G_{L0,T} \quad G_{L2,T} - G_{L1,T} \quad \dots \quad G_{Lm,T} - G_{Lm-1,T}]' \quad (15)$$

$$x_T = [\overline{g_{1,T}} \quad \overline{g_{2,T}} \quad \overline{g_{3,T}} \quad \dots \quad \overline{g_{L,T}}]' \quad (16)$$

이 후, 학습단계에서 구한 방향별 평균 프로파일 x_{mT} 와의 차이 값 E_T 를 식(17)과 같이 계산한다.

$$E_T = |x_T - x_{mT}| \quad (17)$$

E_T 의 값이 가장 작은 방향을 식(18)을 이용하여 T_{min} 을 구한다.

$$T_{min} = \operatorname{argmin}(E_T) \quad (18)$$

최적 방향을 선택한 다음, 해당 방향을 기준으로 직선상의 탐색공간에서 비용함수 f_T 를 식(19)와 같이 계산하며 변수 T_{min} 은 4방향 중 최소 오차를 기록한 방향을 나타낸다. 이때 최적의 지점을 찾기 위한 탐색 공간은 Fig. 4(b)와 같이 표현될 수 있다. 식(19)에서 x_T 는 검토 대상인 프로파일 벡터, x_{mT} 는 방향 인덱스 T에 대한 학습단계에서 구해진 평균 프로파일 벡터이고, S_{gT} 는 방향 인덱스 T에 대하여 학습단계에서 구해진 공분산을 의미한다.

$$f_T(x) = (x_T - x_{mT})' S_{gT}^{-1} (x_T - x_{mT}) \quad (19)$$

Fig. 2의 방향성 프로파일과 2.3절의 Hahn이 제안

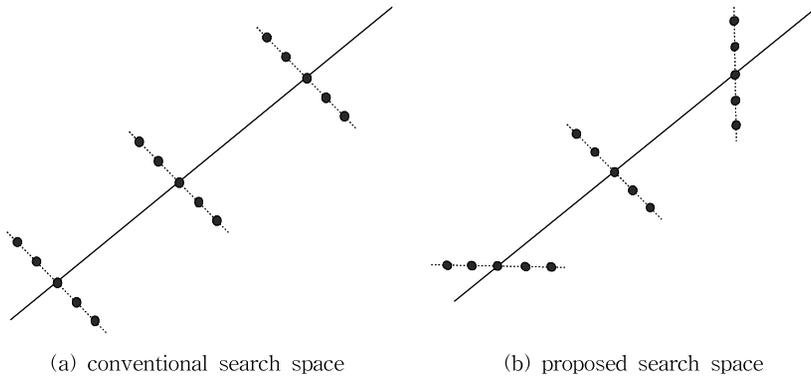


Fig. 4. Example of search space for 3 adjacent landmarks in testing step.

한 형태정렬을 결합하여 랜드마크 추출의 성능을 개선할 수 있다.

4. 실험 결과 및 고찰

4.1 실험영상

본 논문에서 사용한 데이터베이스는 AR database[7]이며 샘플을 Fig. 5에 나타내었다. 이 데이터베이스는 남성 76명-300장, 여성 60명-208장에 대한 정면 위주의 칼라 얼굴사진을 포함하고 있으며, 표정 변화와 평균적인 밝기 값의 변화를 수반한다. 수동으로 제작한 22개의 얼굴 특징 점으로 구성된 랜드마크를 제공한다. 본 논문에서는 Viola와 Jones의 방법[2]을 적용하여 초기 얼굴영역의 추출이 가능한 500장의 영상을 선택하여 입력영상의 집합으로 사용하였다.

학습단계에서는 입력영상 집합 중 200장을 이용하였고, 시험단계에서는 500장의 입력영상 전체를 사용한 경우와 학습단계에 포함되지 않은 300장만을

대상으로 실험하였다.

4.2 성능 평가

제안한 방법과 기존의 방법으로 추출한 랜드마크를 Fig. 7에 나타내었다. 제1행은 209번 영상, 제2행은 319번 영상, 마지막 행은 404번 영상을 예로 들었고, 제1열은 사람이 수동으로 기록한 기준 랜드마크, 제2열은 Cootes 방법, 제3열은 Hahn의 방법, 제4열은 방향성 랜드마크, 제5열은 제안한 Hahn과 방향성 프로파일을 결합한 방법으로 구한 랜드마크이다.

추출 성능을 평가하기 위한 기준을 추출 정확도와 실행시간으로 표현하였다. 입력영상 500장에 대하여 영상별로 정확도와 실행시간을 히스토그램으로 분포형태를 계산하여 Fig. 8에 나타내었다. 정확도는 랜드마크의 추정 오차를 화소(pixel) 단위로, 실행시간은 초 단위로 표현된다.

성능평가 척도는 Viola와 Jones[2] 등이 사용한 ROC 그래프를 이용하였고 Fig. 9에 나타내었다.



Fig. 5. Example of sample images from AR database.

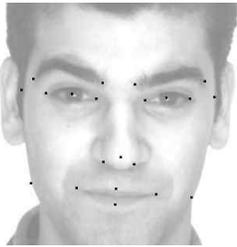


Fig. 6. Example of landmark position.

Fig. 9에서 가로축의 오차 값 35를 기준으로 살펴 보면, Cootes의 방법은 183장, Hahn의 방법은 296장, 방향성 프로파일만 적용한 경우 335장, 방향성 프로파일과 Hahn의 방법을 결합한 경우 368장의 결과를 얻었다. Cootes의 경우는 총 500장의 영상에 대하여 각각의 영상에서 모든 랜드마크들에 대한 추정 평균 오차 값이 35 이하인 영상의 수가 183장임을 나타낸다. 가장 이상적인 추정의 경우는 가로축 오차 값 0에

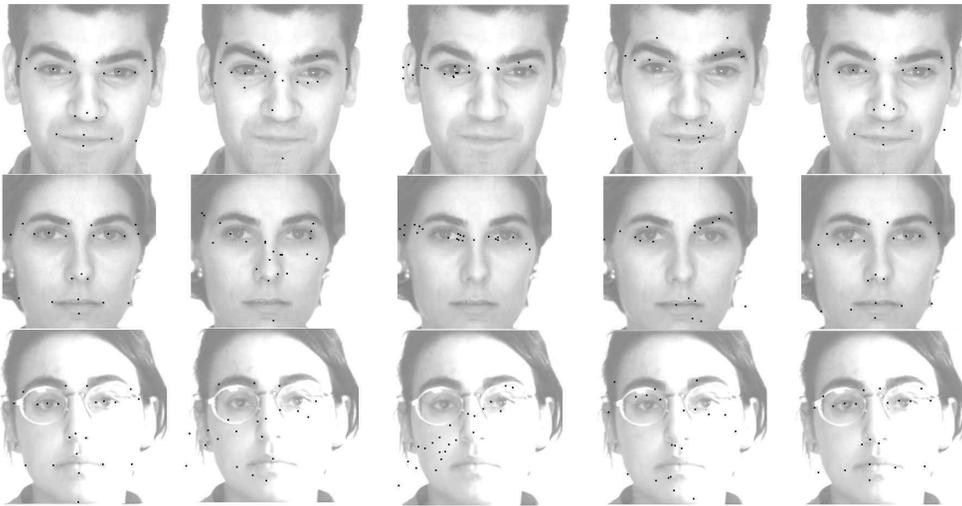


Fig. 7. Example landmarks extracted by conventional and proposed method.

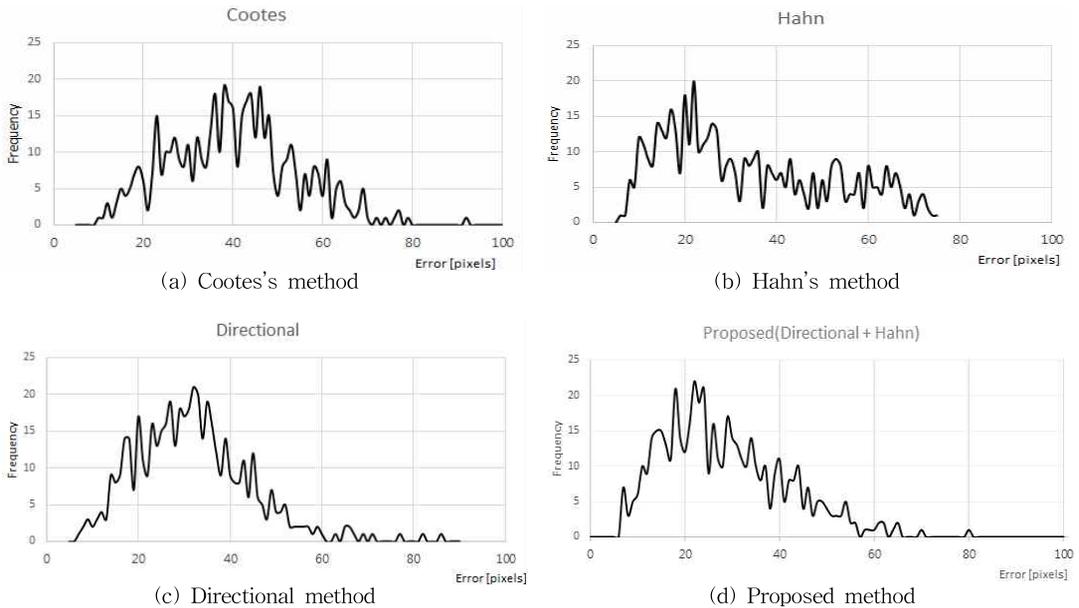


Fig. 8. Comparison of performance by conventional and proposed method.

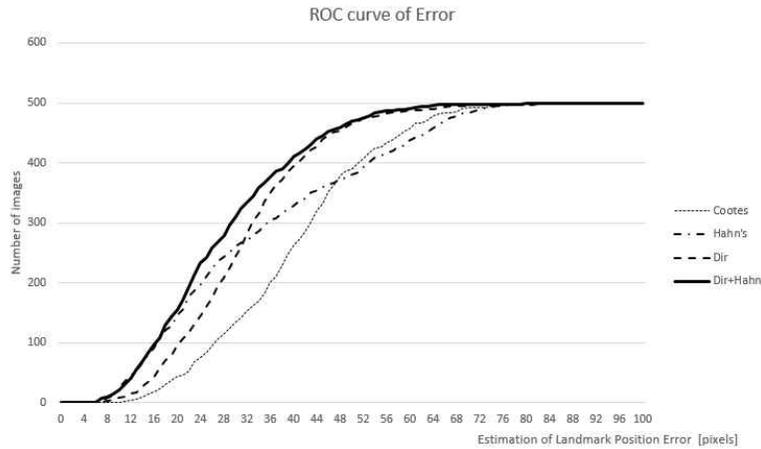


Fig. 9. ROC curve of comparison.

Table 1. Performance parameters for conventional and proposed method(500 images).

Terms	Cootes's	Hahn's	Directional profile	Proposed
Average Error [pixel]	39.460	33.731	31.207	27.720
Standard deviation	13.968	18.545	12.264	12.840
Execution time [sec]	605.6	595.5	606.4	635.7

Table 2. Performance parameters for conventional and proposed method(300 images)

Terms	Cootes's	Hahn's	Directional profile	Proposed
Average Error [pixel]	40.509	35.795	32.498	28.927
Standard deviation	12.807	19.526	12.302	13.032

서 500장의 값을 가지며, 이는 모든 영상에서 기준으로 사용하는 랜드마크와 추정된 랜드마크가 완전히 일치하는 것을 의미한다. Table 1에 나타낸 것과 같이 단순히 오차 값의 평균치만을 비교하는 것이 아니라 전체적인 오차 분포를 고려한 성능을 평가할 수 있다. 방향성 프로파일과 Hahn의 형태정렬을 결합한 제안한 방법이 368장으로 가장 우수하였고, 방향성 프로파일만 적용한 경우, Hahn, Cootes의 방법 순으로 추정 오차가 증가하였다.

또한, 정확도를 간단하게 평가하기 위하여 영상 1장당 추정오차의 평균값과 표준편차를 계산하였고, 실행시간은 500장 전체를 기준으로 측정하여 Table 1에 나타내었다. 학습단계에 포함되지 않은 300장의 영상에 대한 시험결과는 Table 2에 나타내었다.

5. 결 론

본 논문에서는 Cootes, Hahn 등이 제안한 얼굴영

역에 대한 랜드마크 추출 방법을 개선하기 위하여 방향성 프로파일을 도입한 ASM 방법을 제안하였다. 제안한 방법은 500장의 입력영상에 대하여 영상 1장 기준으로 (평균 오차 27.72 화소, 표준 편차 12.84)의 성능을 보였다. 이는 Cootes의 (39.46, 13.968), Hahn의 (33.731, 18.545)보다 우수한 결과이며, 기존의 방법들이 1개의 방향만을 고려한 것에 비하여, 제안한 방법은 4개의 방향을 고려하였지만 실행시간은 거의 대등한 수준이므로 실행에 소요되는 시간의 부담이 거의 없는 것이 장점이다. 추후 연구 방향은 2차원 프로파일의 특성을 최대한 반영할 수 있도록 1차원 프로파일을 개선하는 것이다.

REFERENCES

[1] T.F. Cootes, C.J. Taylor, D.H. Cooper, and J. Graham, "Active Shape Models-Their Training and Application," *Computer Vision and*

Image Understanding, Vol. 61, No. 2, pp. 38-59, 1995.

[2] P. Viola and M. Jones, "Rapid Object Detection Using a Boosted Cascade of Simple Features," *Computer Vision and Pattern Recognition Conference*, pp. 511-518, 2001.

[3] M.H. Mohammad, A.M. Mohamed and A. Ansari, "Improved Active Shape Model for Facial Feature Extraction in Color Images," *Journal of Multimedia*, Vol. 1, No. 4, pp. 21-28, 2006.

[4] S. Milborrow and F. Nicolls, "Locating Facial Features with an Extended Active Shape Model," *Proceedings of the 10th European Conference on Computer Vision: Part IV*, pp. 504-513, 2008.

[5] K. Seshadri and M. Savvides, "Robust Modified Active Shape Model for Automatic Facial Landmark Annotation of Frontal Faces," *Proceedings of the International Conference on Biometrics: Theory, Applications and Systems*, pp. 319-326, 2009.

[6] H. Hahn, "Proposing Shape Alignment for an Improved Active Shape Model," *Journal of Korea Multimedia Society*, Vol. 15, No. 1, pp. 63-70, 2012.

[7] D. Liya and A.M. Martinez, "Features Versus Context: An Approach for Precise and Detailed Detection and Delineation of Faces and Facial Features," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 32, No. 11, pp. 2022-2038, 2010.



김 정 업

1986년 3월 ~ 1990년 2월 경북대학교 전자공학과 학사
 1990년 3월 ~ 1992년 2월 경북대학교 대학원 전자공학과 석사
 1992년 3월 ~ 2001년 2월 경북대학교 대학원 전자공학과 박사

1994년 6월 ~ 2001년 2월 삼성종합기술원 전문연구원
 2001년 3월 ~ 2013년 2월 영산대학교 게임콘텐츠학과 부교수
 2013년 3월 ~ 현재 영산대학교 자유전공학부 부교수
 관심분야 : 칼라영상처리, 컴퓨터 비전.