

# 안정적인 실시간 얼굴 특징점 추적과 감정인식 응용

## Robust Real-time Tracking of Facial Features with Application to Emotion Recognition

안 병 태<sup>1</sup>, 김 응 희<sup>2</sup>, 손 진 훈<sup>3</sup>, 권 인 소<sup>†</sup>

Ahn Byungtae<sup>1</sup>, Kim Eung-Hee<sup>2</sup>, Sohn Jin-Hun<sup>3</sup>, Kweon In So<sup>†</sup>

**Abstract** Facial feature extraction and tracking are essential steps in human-robot-interaction (HRI) field such as face recognition, gaze estimation, and emotion recognition. Active shape model (ASM) is one of the successful generative models that extract the facial features. However, applying only ASM is not adequate for modeling a face in actual applications, because positions of facial features are unstably extracted due to limitation of the number of iterations in the ASM fitting algorithm. The unaccurate positions of facial features decrease the performance of the emotion recognition.

In this paper, we propose real-time facial feature extraction and tracking framework using ASM and LK optical flow for emotion recognition. LK optical flow is desirable to estimate time-varying geometric parameters in sequential face images. In addition, we introduce a straightforward method to avoid tracking failure caused by partial occlusions that can be a serious problem for tracking based algorithm. Emotion recognition experiments with k-NN and SVM classifier shows over 95% classification accuracy for three emotions: "joy", "anger", and "disgust".

**Keywords:** facial feature, active shape model, optical flow, emotion recognition

### 1. 서 론

얼굴 특징점 검출 및 추적은 얼굴인식, 의료 영상분석, 시선추정, 그리고 감정인식 같은 여러 분야들의 가장 기본이 되는 단계이다. 이런 분야에서 모델 기반의 접근법이 널리 연구되어 왔다. 어떤 객체의 형태의 비선형적인 변형이나 움직임을 모델링하는 방법으로 가장 널리 쓰이는 접근법은 점 분포 모델 (point distribution model)이다. PDM은 특징점들의 분포를 기반으로 형태모델을 생성하고, 생성된 모델의 형태를 변화시키면서 영상에서 특정 영역을 분할하

는 것이다. 이는 active shape model (ASM)으로 발전하였고<sup>[1]</sup>, 객체의 외형(appearance)을 모델링하는 active appearance model(AAM)로의 확장도 이루어졌으며<sup>[2]</sup>, 20년이 넘도록 연구 및 활용되고 있다. ASM과 AAM을 비교하면, AAM은 특징점 추출이 안정적이고 추적이 잘 되는 장점을 가지는 반면 처리 속도가 느리고 최초 정합(fitting)에 민감하며 모델을 정합하는 과정에서 국부 최소점(local minima)에 빠지기 쉽다는 단점이 있다. 이에 반해 ASM은 처리 속도가 빠르고, 모델의 일반성(generality)이 제한적이지 않아 모델의 여러 가지 변형을 잘 표현할 수 있으며, 조명변화로 인한 객체의 외형변화에 덜 민감하여 실시간 시스템에서 많이 활용된다<sup>[3]</sup>. ASM의 학습된 모델은 각 특징점들의 평균 위치정보와 훈련셋(training set)에 나타난 여러 가지 형태의 변형들을 표현할 수 있는 파라미터들을 가지고 있다. 미리 학습된 초기 값들과 모델을 기반으로, ASM은 입력영상 내 특정 객체의 변형된 형태에 적응적으로 정합 될 수 있다. 그러나 실시간 감정인식과 같은 실제 응용에 오직 ASM만 사용하는 것은 적합하지 못하다. 왜냐하면 ASM

Received : May 11, 2013; Reviewed : Jun. 18, 2013; Accepted : Jul. 25, 2013

※ This work was supported by the Converging Research Center Program funded by the Ministry of Education, Science and Technology (2012K001339).

<sup>1</sup> Graduate Student, Robotics Program, KAIST (btahn@rev.kaist.ac.kr)

<sup>2</sup> Graduate Student, School of Dentistry, Seoul National University (eunghee.kim@daum.net)

<sup>3</sup> Professor, Department of Psychology, Chungnam National University (jhsohn@cnu.ac.kr)

<sup>†</sup> Corresponding author: Professor, Department of Electrical Engineering, KAIST (iskweon@kaist.ac.kr)

정합 알고리즘은 비용함수(cost function)를 반복적으로 최소화하여 정합을 하게 되는데, 실시간 시스템에서는 충분히 많은 반복을 할 수가 없고, 또한 영상의 노이즈 등으로 인해서 모델이 정확한 위치에 정합이 되지 않는다. 뿐만 아니라 이로 인해 마치 모델이 흔들리고 있는 것 같은 떨림(jittering) 현상이 연속적인 영상에서 나타나게 되는데, 이 때문에 감정 추정에 사용되는 특징량을 구하는데 정확성이 떨어지게 되고 이는 전체 시스템의 성능을 저하시키는 요인이 된다.

본 논문에서는 얼굴 특징점들의 정확하고 안정적인 실시간 검출을 위하여, Lukas-Kanade 옵티컬 플로우(LK optical flow) 기반의 추적 방법을 ASM에 적용한 알고리즘을 제안한다. 일반적으로 LK 옵티컬 플로우는 변화율(gradient) 기반의 방법으로써 연속적인 영상에서 시간에 따라 변하는 기하학적인 파라미터를 추정하는데 적합하고 다양하게 응용되고 있다<sup>4)</sup>. 나아가 추적 기반의 방법에서는 가려짐(occlusion)으로 인한 추적실패가 전체 시스템의 성능을 떨어뜨리는 주된 요인 중 하나로 대두되는데, 본 논문에서는 알고리즘을 계층적으로 구성하여 부분적 가려짐에도 강인하게 모델을 정합하는 방법을 제안한다.

## 2. 관련 연구

### 2.1 Active Shape Model (ASM)

앞서 언급한 대로, ASM은 전체적으로 PDM과 정합 알고리즘으로 구성되어 되어있고, 형태가 변동적인 객체의 여러 변형 형태를 작은 수의 변형 모드(mode)들의 선형적 조합으로 나타낸다<sup>2)</sup>. ASM을 사용하여 영상에서 특징점들을 추출하기 위한 전체 과정은 두 단계로 나뉜다. 통계적 형태 모델을 생성하는 단계와 각 특징점의 영상 프로파일 기반의 PDM을 이용한 적응적 탐색(searching) 단계이다.

통계적 형태 모델을 생성하기 위해서, 훈련 영상들에 있는 특징점들을 식 (1)과 같이 정의하고, 특징점들의 최초 위치가 PDM에 의하여 결정된다.

$$X = [x_1, y_1, x_2, y_2, \dots, x_n, y_n]^T \quad (1)$$

여기서  $X$ 는 특징점들 좌표의 집합을 의미한다. 각 학습영상에서 식 (1)의 특징점들을 기반으로 하여 훈련 집합을 생성하고, 이로부터 유효한 형태를 생성하기 위해서 정렬(alignment) 알고리즘과 주성분분석을 거쳐 식 (2)와 같이 새로운 형태를 표현한다.

$$s \cong \bar{s} + Pb \quad (2)$$

여기서  $s$ 는 새롭게 표현된 형태(shape)이고,  $\bar{s}$ 와  $P$ 와  $b$ 는 각각 정렬과 주성분분석을 통해 나온 평균 형태(mean shape), 공분산 행렬의 고유벡터(eigenvector), 그리고 형태 파라미터이다.

Milborrow와 Nicolls는 기존의 ASM 정합 알고리즘에서 탐색에 사용되는 각 특징점의 1차원의 프로파일을 2차원으로 수정하여 정합의 정확도를 높이고, 각 특징점의 공분산 행렬에서 중심에서 거리가 먼 쪽의 원소들을 0으로 만들어 무시함으로써 처리 속도도 높였다<sup>5)</sup>. 본 논문에서는 이를 기본 ASM 알고리즘으로 사용하였다.

### 2.2 Lucas-Kanade (LK) Optical Flow

동적으로 움직이는 연속적인 얼굴 영상에서는 각 특징점들의 위치뿐만 아니라 시간에 따른 위치 변화도 고려되어야 한다. 연속적인 영상에서 ASM의 특징점들이 이전 절에서 기술한대로 결정되고, 프레임간의 옵티컬 플로우도 정의된다. 옵티컬 플로우의 기본개념은 시간  $t$ 에서의 영상  $I_t$ 와 시간  $t+1$ 에서의 영상  $I_{t+1}$  양쪽 모두에 존재하는 특징점 화소들의 움직임을 나타내는 벡터들이다<sup>4)</sup>. 두 인접한 프레임 사이의 2차원 좌표  $p_i = (x_i, y_i)$ 에 위치하고 있는 점의 움직임은  $p_i$ 에 인접한 아주 작은 상수로 근사화 된다.  $I_t$ 에서의 특징점을  $[x_i^t, y_i^t]^T$ 라고 할 때, 같은 특징점이 영상  $I_{t+1}$ 에서는  $[x_i^t + d_x, y_i^t + d_y]^T$ 라고 정의되고 옵티컬 플로우는 식 (3)을 최소화 시키는 파라미터  $d_x$ 와  $d_y$ 로 구성된 함수로 표현된다. 여기서  $w_x$ 와  $w_y$ 는 각각 LK 옵티컬 플로우에서 사용하는 마스크 윈도우의  $x, y$  방향으로 크기를 의미한다.

$$\epsilon(d_x, d_y) = \sum_{x=x_i^t-w_x}^{x_i^t+w_x} \sum_{y=y_i^t-w_y}^{y_i^t+w_y} [I_1(x, y) - I_2(x + d_x, y + d_y)] \quad (3)$$

식 (3)은 다시  $Av=b$ 의 행렬 형태로 구성될 수 있고, 파라미터  $A, v$ , 그리고  $b$ 는 각각 아래와 같다.

$$a) A = [I_{x(p_i)} \ I_{y(p_i)}; \dots; I_{x(p_n)} \ I_{y(p_n)}]^T$$

$$b) v = [V_x \ V_y]^T$$

$$c) b = [-I_{t(p_i)}, \dots, I_{t(p_i)}]^T$$

여기서,  $I_{x(p_i)}, I_{y(p_i)}$ , 그리고  $I_{t(p_i)}$ 는 각각  $x, y$ , 그리고  $t$ 에 대한 편미분을 나타내며, 얻고자 하는 옵티컬 플로우  $v_i$ 는 식 (4)와 같이 구할 수 있다<sup>6)</sup>.

$$v_i = \begin{bmatrix} \sum_{i=1}^n I_x(p_i)^2 & \sum_{i=1}^n I_x(p_i)I_y(p_i) \\ \sum_{i=1}^n I_x(p_i)I_y(p_i) & \sum_{i=1}^n I_y(p_i)^2 \end{bmatrix} \begin{bmatrix} -\sum_{i=1}^n I_x(p_i)I_t(p_i) \\ -\sum_{i=1}^n I_y(p_i)I_t(p_i) \end{bmatrix} \quad (4)$$

### 3. 얼굴 특징점 추적 프레임워크와 실험구성

#### 3.1 얼굴 특징점 추적 프레임워크

본 논문에서 제안한 얼굴 특징점 추적 알고리즘의 전체 흐름을 그림 1에 도식화 하였다. 먼저 multi-resolution ASM (MRASM)으로 입력 영상에 얼굴 모델 정합을 수행한다. MRASM은 ASM 정합 알고리즘의 다중해상도 접근 방식으로 시간과 정확도 측면에서 더 나은 성능을 보여준다. 그렇지만 얼굴 특징점 추출에 MRASM만을 매 프레임 검출에 의한 추적(tracking-by-detection)방식으로 적용한다면 특징점들의 위치가 연속적인 영상에서 마치 떨리는 것처럼 안정적이지 않게 추출되고, 이는 전체 시스템의 성능 저하를 야기한다. 따라서 검출에 의한 추적 방식이 아닌, 빠르게 큰 움직임에도 잘 추적 할 수 있도록 영상피라미드 방법을 적용한 LK 옵티컬 플로우 알고리즘으로 추적을 한다.

한편, 추적 기반의 알고리즘이 특징점들을 안정적으로 추출해주긴 하지만, ASM이 추적 기반의 정합 알고리즘과 함께 사용될 때는 누적오차나 순간적인 가려짐으로 인해

특징점 추적에 실패하는 경우가 필연적으로 발생한다. 이는 추적에 사용되는 특징점을 중심으로 한 프로파일 윈도우 내의 정보가 가려짐으로 인해 완전히 바뀌어 버리기 때문이다. 이를 해결하기 위해 다양한 연구들이 있어왔지만<sup>[7]</sup>, 본 논문에서는 전체 알고리즘을 두 단계 계층적으로 구성하여 앞단에는 LK 옵티컬 플로우를 이용하여 추적을 수행하고 동시에 뒷단에서 매 프레임 ASM 정합을 실행한다. 그리고 식 (5)를 만족하도록 특징점의 위치를 제한하여 추적에 실패한 특징점은 독립적으로 MRASM 정합 단계로 돌아가도록 구성하여 간단하게 문제를 해결하였다.

$$p_i = \begin{cases} (x_i^{ASM}, y_i^{ASM}), & \text{if } |p_i^{tracked} - p_i^{ASM}| > th \\ (x_i^{tracked}, y_i^{tracked}), & \text{else} \end{cases} \quad (5)$$

여기서  $p_i^{ASM}$ 은 ASM에 의해 정합된 특징점의 위치이고  $p_i^{tracked}$ 는 LK 옵티컬 플로우에 의해 추적된 특징점의 위치이다.  $i$ 는 특징점의 인덱스이며  $th$ 는 임계값으로써 유클리디안 거리를 의미한다.

#### 3.2 감정인식 실험구성

감정인식 알고리즘으로써 가장 기본이 되는 두 가지 방법론인 k-NN (k-Nearest Neighbor) 분류기와 커널 SVM (Support Vector Machine) 분류기를 이용하여 실험을 수행하였다.

k-NN은 비변수적(non-parametric) 분류 알고리즘이다. 데이터 분포에 대해 어떠한 가정도 하지 않고 훈련 데이터를 일반화시킨 모델도 생성하지 않는다. 다시 말해, 명시적인 훈련단계 없이 모든 훈련 데이터들을 사용하여 테스트 할 새로운 입력을 분류하는 알고리즘이다. 데이터들을 벡터로 표현하여 다차원의 특징 공간 (feature space) 혹은 측정 공간 (metric space)에서 데이터 포인트들 사이의 거리를 계산한다. 이때 각 벡터는 각 범주(class) 이름과 일대일로 짝지어져 있다. k-NN이 분류를 하는 방식은 다음과 같다: k-NN 분류기에 테스트 벡터가 입력이 되면 분류기는 가지고 있는 훈련 데이터 벡터와 테스트 벡터를 비교하여 훈련 데이터 벡터 중에서 k개의 가장 근접한 벡터들을 선택한다. 그리고 선택된 k개의 벡터들 중 가장 빈번하게 선택된 벡터의 범주로 시험 벡터를 분류한다. 만약 범주가 2 개라면 동일하게 투표(voting)되는 것을 방지하기 위해 k는 보통 홀수로 정의한다. 만약 k=1이라면 INN은 가장 가까운 벡터가 나타내는 범주로 테스트 벡터를 분류함을 의미




Fig. 1. Schematic flow chart of the facial feature tracking system

한다. k-NN을 감정인식 연구에 적용하면 다음과 같은 흐름이 된다. 테스트 얼굴 영상이 입력되면 얼굴 특징점의 조합으로 이루어진 특징벡터를 추출하여 k-NN 분류기에 입력이 되고, 분류기는 훈련 데이터에 있는 얼굴표정 특징 벡터들 중에서 입력된 테스트 벡터와 가장 유사한 k개의 벡터(표정)들을 선택하고, 가장 많이 선택된 범주의 감정으로 분류를 한다.

SVM의 기본개념은 이진 분류기(binary classifier)로써 다차원의 데이터를 두 가지의 범주로 분류시키는 초평면(hyper plane)을 찾는 분류기이다. 학습단계와 테스트 단계로 나뉘는데,  $l$  개의 훈련 데이터  $\{x_i \mid i = 1, 2, \dots, l\}$ 가  $y = \{-1, 1\}$ 로 표현되는 두 가지의 범주를 가지고 있을 때,  $f(x) = \text{sign}(w \cdot x + b)$ 가 데이터를 분할하는 결정함수가 된다. 하지만 데이터가 선형적으로 분리 불가능한 경우 SVM은 커널을 이용하여 데이터를 선형분리 가능한 고차원의 특징 공간에 매핑하고 그 공간에서 데이터를 두 가지의 범주로 나누는 초평면을 찾는다. 이를 위해,  $z = \phi(x)$ 를 정의하여 d-차원의 입력 벡터  $x$ 를 d'-차원의 벡터  $z$ 로 변환한다. 그리하여, 변환된 훈련 벡터  $\{\phi(x_i), y_i\}$ 를 분할하는 초평면  $f(x)$ 를 찾는다.  $f(x)$ 는 다음 식(6)과 같다.

$$\begin{aligned} f(x) &= \text{sign}(w \cdot \Phi(x) + b) \\ &= \text{sign}\left(\sum_i \alpha_i y_i (\Phi(x_i) \cdot \Phi(x)) + b\right) \end{aligned} \quad (6)$$

여기서  $\phi()$ 는 많은 계산이 필요한데 d-차원의 특징공간에서의 내적 즉, 커널함수  $K(x_a, x_b) = \phi(x_a) \cdot \phi(x_b)$ 를 이용하면  $z = \phi(x)$ 를 계산하지 않아도 되고 식(6)의 결정함수는 다음 식(7)과 같이 도출된다.

$$f(x) = \text{sign}\left(\sum_i \alpha_i y_i (K(x_i \cdot x) + b)\right) \quad (7)$$

또한, 최적화 문제에서는 라그랑제 승수  $\alpha_i$  중 일부만이 0이 아닌데, 이들은 두 범주를 나누는 초평면에 가장 근접한 훈련 데이터(support vectors라고 불림, 여기서 이름이 유래)에서 발생하며, 이들을 이용하여 최적화를 효율적으로 수행한다. 또한, 범주의 개수가 두 가지를 초과하는 분류에서는 기본 SVM의 이진 분류기 여러 개를 사용하거나, 투표방식을 사용한다.

## 4. 실험 결과

### 4.1 ASM and LK optical flow

제안한 알고리즘을 Visual Studio, i7 core, 8GB RAM의 환경에서 구현하였고, 전체 처리시간은 20ms 미만으로 50fps이상의 속도를 보였다. 그림 2는 제안된 알고리즘에 의해 얼굴 특징점들이 입력 영상에 정합된 그림이다. LK 옵티컬 플로우 기반의 추적 기법을 적용시키기 전과 후의 68개 각 특징점들 위치의 표준편차를 비교하여 그림 3에 나타내었다. 파란색은 적용을 시키기 전이고 붉은색은 적용시킨 후의 정합결과이다. 위치의 표준편차가 평균 25% 가량 줄어들었고 전체적으로 안정적으로 특징점들이 추적되었다.

그림 4는 식 (5)를 만족하도록 특징점의 위치를 제한하여 부분적 가려짐에 강인한 방법을 적용시킨 결과를 나타낸다. 왼쪽 열이 적용 전인데 얼굴 특징점들이 손에 의해서 한번 가려지면 복구될 수 없이 계속 정합에 실패하게 되는 반면 오른쪽은 적용 후 결과로써 추적하는 특징점이 순간적으로 가려지더라도 다시 제대로 정합되는 것을 보여준다.




Fig. 2. MRASM fitted to the facial features




Fig. 3. Standard deviation of positions of the facial features



Fig. 4. Reinitialization of facial features after partial occlusions

### 4.2 감정인식

기쁨, 혐오, 그리고 분노 3가지 감정에 대하여 분류실험을 하였다. 데이터 셋은 피실험자에게 기쁨, 혐오, 그리고 분노를 유발하는 영상을 보여주거나 상황을 연출하고 피실험자의 표정 변화를 녹화한 다음, 표정이 정점에 이른 영상을 캡처하여 훈련 데이터 집합을 생성했다.

449개의 훈련 데이터에서 얼굴 특징점들의 위치를 추출하고, Antonio 등<sup>[8]</sup>, Zhang 등<sup>[9]</sup>, 그리고 Bimler 등<sup>[10]</sup>이 보고한 특징 중 49개를 이용하였고, 이 중 k-NN 분류 모델에서 가장 높은 성능을 보인 특징들이 표 1에 기술되어 있다. k-NN 분류기는 입력 영상에서 표 1의 특징들로 이루어진 벡터를 입력으로 받아 훈련 데이터 집합으로부터 가장 유사한 k개의 벡터를 선택하여 그 중 가장 많이 선택된 표정을 결과로 분류하고, SVM경우는 감정(기쁨, 혐오, 분노)마다 긍정과 부정으로 분류하는 이진 분류기를 각각 생성하여 사용하였다. 입력영상에 대하여 3개의 분류기가 판단

Table 1. Features used in k-NN classifier for emotion recognition

	Name	Description
1	Edu2	bending degree of right eyebrow
2	Edu4	length of width / height of mouth
3	Edu7	height of open eye / height of open mouth
4	Edu10	width of bottom sides of nose / width of mouth
5	Edu11	Edu2 / Edu4
6	Edu14	(width of eyebrow / height of eyebrow) / Edu10

Table 2. Result of emotion recognition by k-NN classifier (n=448)

	Anger	Disgust	Joy
Anger	290	3	0
Disgust	12	113	0
Joy	0	2	128

Table 3. Result of emotion recognition by SVM classifier (n=448)

	Anger	Disgust	Joy
Anger	293	0	0
Disgust	3	122	0
Joy	0	0	128

을 하고 그 분류 결과에서 빈도가 높은 감정을 선택하는 투표방식을 사용하였으며, 빈도가 동일할 경우 분류불가로 처리하였다.

LOOCV (Leave-One-Out Cross Validation) 방법으로 평가하였으며 총 448번 수행을 하였다. 표 2와 3에 k-NN 과 SVM 분류기 각각의 실험결과를 오차행렬(Confusion matrix)로 나타내었다.

표 2에 나타나듯이, '분노'의 경우 약 99%의 정확도를 보였고, '혐오'는 약 90%, 그리고 '기쁨'은 약 98%의 정확도로 전체 분류 정확도는 약 96%로 아주 정확하게 분류하였다. 이는 Sebe 등<sup>[11]</sup>이 제안한 동일한 k-NN 분류기에 12개의 얼굴 모션 유닛(motion unit)을 특징 벡터로 사용한 방법론의 평균 정확도 93%보다 좋은 결과이다.

SVM 분류기의 경우 polynomial 커널 함수를 사용하였을 때 가장 높은 성능을 보였는데, 표 3에서 보듯이, '분노'의 경우 총 293번의 테스트 모드를 올바르게 분류하였고 (정확도 100%), '혐오'는 약 98%, '기쁨'도 총 128번의 테스트 모드를 올바르게 분류하여 (정확도 100%), 전체 분류 정확도는 약 99%로써 아주 높은 정확도를 보였다. 이는 Valstar 등<sup>[12]</sup>이 제안한 8개의 얼굴 특징점과 Gentle boost 및 SVM 조합의 분류기를 사용한 방법론의 평균 정확도 90.7%보다 우수한 성능이다. 이전 연구들이 본 연구와 동일한 분류기를 사용하였지만 본 연구와 같은 특징 벡터를 사용한 것은 아니기 때문에 감정인식에서 직접적인 추적기의 성능을 비교하기 어렵지만, 본 논문에서 제안한 안정적 인 얼굴 특징점 추적을 이용한 특징벡터의 구성 및 분류기의 조합이 타당하게 우수한 방법임을 보여준다.

## 5. 결론

감정인식과 같은 주제는 감정 분류기의 입력이 되는 얼굴 영상의 특징벡터의 정확도가 아주 중요하다. 본 논문에




서는 ASM과 LK 유틸리티 플로우를 이용하여 안정적이고 정확한 실시간 얼굴 특징점 추적 알고리즘을 제안하였다.

k-NN과 SVM 기반의 감정분류기를 사용한 실험은 LOOCV 평가 방법으로 약 96%와 99%의 높은 정확도를 보였다 (n=448). 추후 다양한 조명조건, 자세 및 감정표현에도 강인하게 얼굴 특징점들을 추출 및 추적 할 수 있는 얼굴모델 정합 알고리즘을 연구할 계획이다.

## References

- [1] T. F. Cootes, C. J. Taylor, D. H. Cooper, J. Graham, "Active Shape Models-Their Training and Application", *Computer Vision Image Understand*, Vol. 61, No. 9, pp. 38-59, 1995.
- [2] T. F. Cootes, G. Edwards, C. Taylor. "Active appearance models", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, No. 6, pp. 681-685, 2001.
- [3] M. Zhou, L. Liang, J. Sun, Y. Wang, "AAM based Face Tracking with Temporal Matching and Face Segmentation", *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 701-708, 2010.
- [4] J. K. Kearney, W. B. Thompson, "Optical Flow Estimation: An Error Analysis of Gradient-based Methods with Local Optimization", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 9, No. 2, pp. 229-244, 1987.
- [5] M. Stephen, N. Fred, "Locating facial features with an extended active shape model", *Proceedings of the 10th European Conference on Computer Vision*. Vol. 4, pp. 504-513, 2008.
- [6] M. Kass, A. Witkin, D. Terzopoulos, "Snakes: Active Contour Models", *International Journal of Computer Vision*, Vol. 1, No. 4, pp. 321-331, 1988.
- [7] R. Gross, I. Matthews, S. Baker, "Active Appearance Models with Occlusion", *Image and Vision Computing*, Vol. 24, No. 6, pp. 593-604, 2006.
- [8] Antonio G., Sorci M., Bierlaire M., Thiran J., "Discrete choice models for static facial expression recognition", *Proceedings of the 8th International Conference on Advanced Concepts for Intelligent Vision Systems*, Vol. 4179, pp. 710-721, 2006.
- [9] Zhang Y., Ji Q., "Facial expression understanding in image sequences using dynamic and active visual information fusion", *Proceedings of the 9th International Conference on Computer Vision*, Vol. 2, pp. 1297-1304, 2003.
- [10] Bimler D., Paramei G., "Facial-expression affective attributes and their configural correlates: components and categories", *Spanish Journal of Psychology*, Vol. 9, pp. 19-31, 2006.
- [11] M. Pantic and L. J. M. Rothkrantz, "Case-based reasoning for user-profiled recognition of emotions from face images," *Proceedings of the International Conference on Multimedia*, pp. 391-394, 2004.
- [12] M. Valstar, M. Pantic, Z. Ambadar and J. F. Cohn, "Spontaneous versus posed facial behavior: Automatic analysis of brow actions", *Proceedings of the International Conference on Multimodal Interfaces*, pp. 162-170, 2006.



### 안 병 태

2007 금오공과대학교 전자공학부 (학사)  
2011 성균관대학교 바이오메카트로닉스전공 (석사)  
2012~현재 KAIST 로봇공학 학제전공 박사과정

관심분야 : facial model, face analysis



### 김 응 희

2007 선문대학교 컴퓨터정보학부 (학사)  
2009 서울대학교 치의과학과 (석사)  
2009~현재 서울대학교 치의과학과 박사과정

관심분야 : FCA(Formal Concept Analysis), Ontology



**손진훈**

- 1978 고려대학교 심리학과 (학사)
- 1983 고려대학교 심리학과 실험생리(석사)
- 1988 고려대학교 심리학과 실험생리(박사)

1989~현재 충남대학교 심리학과 교수  
관심분야 : Brain Science, Neuroscience



**권인소**

- 1981 서울대학교 기계설계학과(학사)
- 1983 서울대학교 기계설계학과(석사)
- 1990 Carnegie Mellon Univ. Robotic Institute (박사)

1991~1992 일본 도시바 중앙연구소 연구원  
1992~현재 KAIST 전기 및 전자공학과 교수  
관심분야 : Computer Vision