

# 동적 확률 모델 네트워크 기반 휴먼 상호 행동 인식

(Human Interaction Recognition with a Network of  
Dynamic Probabilistic Models)

석 흥 일 <sup>\*</sup> 이 성 환 <sup>\*\*</sup>

(Heung-Il Suk) (Seong-Whan Lee)

**요약** 본 논문에서는 휴먼 객체들의 이동 궤적 정보를 기반으로 휴먼 상호 행동을 인식하기 위한 새로운 모델을 제안한다. 복잡한 휴먼 상호 행동들은 의미있는 작은 단위로 분할될 수 있는데 이를 ‘부-상호 행동’이라 하며, 이들을 표현하는 모델들의 순차적 연결 또는 네트워크로 상호 행동을 모델링한다. 제안하는 모델은 서로 다른 상호 행동들에 공통적으로 나타나는 부-상호 행동들을 공유하도록 함으로써 모델의 복잡도를 낮추어 매우 효율적이다. 상호 행동 네트워크 모델의 동작 분석 및 기준 방법과의 비교 실험을 통해 제안한 방법의 우수성을 확인할 수 있었다.

**키워드** : 휴먼 상호 행동 인식, 동적 확률 모델 네트워크, 동적 베이지안 네트워크, 비디오 서베일런스

**Abstract** In this paper, we propose a novel method for analyzing human interactions based on the walking trajectories of human subjects. Our principal assumption is that an interaction episode is composed of meaningful smaller unit interactions, which we call ‘sub-interactions.’ The whole interactions are represented by an ordered concatenation or a network of sub-interaction models. From the experiments, we could confirm the effectiveness and robustness of the proposed method by analyzing the inner workings of an interaction network and comparing the performance with other previous approaches.

**Key words** : Human Interaction Recognition, Network of Dynamic Probabilistic Models, Dynamic Bayesian Network, Video Surveillance

## 1. 서 론

최근, 컴퓨터 비전 기반의 서베일런스 문제가 크게 대두됨으로 인해 세계적으로 휴먼 중심의 상호 행동에 대한 연구가 커다란 관심을 받고 있다. Oliver 등은 두 명

의 휴먼 객체 사이에서 일어날 수 있는 상호 행동의 발생 시점을 검출하고, 이를 인식하기 위한 프레임워크를 제안하였으며[1], 상호 행동을 모델링하기 위해 통계적 베이지안 방법과 Coupled HMM(CHMM)을 이용하였다. Liu와 Chua는 세 명의 휴먼 객체간에 발생하는 상호 행동을 정의하고, 이를 모델링하기 위한 Observation Decomposed HMM(ODHMM)을 제안하였다[2]. 또한, 일부 연구 그룹에서는 계층적인 방법을 이용하였다. Hongeng 등은 여러 휴먼 객체간에 발생하는 이벤트를 독립-스레드와 다중-스레드로 분할하여 표현하였으며[3], Ryoo와 Aggarwal은 Context Free Grammar를 이용한 서술적 기법 기반의 휴먼 행동 및 상호 행동 인식 시스템을 제안하여, ‘싸움’, ‘악수하기’와 같은 상호 행동을 인식하였다[4].

그러나 이들 모델들의 공통적인 문제점은 상호 행동 패턴의 복잡성에 상관없이 동적 패턴 전체를 하나의 모델로 표현하려는데 있다. 복잡한 상호 행동을 의미 있는

\* 이 논문은 2006년도 교육과학기술부의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업입니다.(No. KRF-2006-311-D00197). 이 연구에 참여한 연구자는 ‘2단계 BK21사업’의 지원을 받았음

† 학생회원 : 고려대학교 컴퓨터학과

hisuk@image.korea.ac.kr

\*\* 종신회원 : 고려대학교 정보통신대학 컴퓨터·통신공학부 교수  
swlee@image.korea.ac.kr

논문접수 : 2009년 7월 22일

심사완료 : 2009년 8월 31일

Copyright©2009 한국정보과학회 : 개인 목적이나 교육 목적인 경우, 이 저작물의 전제 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지 : 소프트웨어 및 응용 제36권 제11호(2009.11)

작은 단위로 분할하여 모델링하고, 이들간의 관계를 이용하여 상호 행동을 인식할 수 있다면 문제의 복잡도를 훨씬 줄일 수 있다. Hakeem과 Shah는 학습 데이터로부터 서브 이벤트들 간의 관계를 표현하는 종속 그래프를 생성하여 이벤트를 모델링하였다[5]. 또한, Xiang과 Gong은 학습 데이터에 대한 레이블링 없이 자동으로 비정상 행동을 검출하기 위한 프레임워크를 제안하였다[6].

본 논문에서는 의미 있는 작은 단위의 상호 행동을 ‘부-상호 행동’이라 정의하고, 휴먼 객체들의 이동 궤적을 관측값으로 한다. 복잡한 휴먼 상호 행동을 부-상호 행동으로 분할 모델링 한 뒤, 이들 모델들을 네트워크로 구성하여 휴먼 상호 행동을 인식하는 방법을 제안한다. 새로운 상호 행동 패턴을 인식할 필요가 있을 경우, Hakeem과 Shah의 방법은 모든 학습 데이터를 이용하여 새로이 종속 그래프를 생성해야 하는 반면, 제안하는 방법은 기존에 모델에 포함되어 있지 않은 부-상호 행동에 대해서만 학습을 하고, 네트워크에 추가하기만 하면 된다는 장점을 가진다. 또한 부-상호 행동간의 전이 확률을 미리 학습된 값을 따르는 것이 아니라, 현재 시간에 관측된 특징값에 기반하여 결정한다. Xiang과 Gong의 방법은 입력 패턴에 대한 확률값을 계산한 뒤, 스펙트럴 클러스터링 방법을 이용하여 인식을 수행하기 때문에 두 단계를 거쳐야 하나, 제안하는 방법은 마지막 입력 관측값에 대한 확률 계산과 동시에 인식 결과를 출력하여 인식 속도면에서 우수하다.

논문의 구성은 다음과 같다. 2절에서는 부-상호 행동 모델을 이용한 상호 행동 네트워크의 생성 및 동적 확률 모델 네트워크에서의 추론 방법을 설명한다. 제안하는 방법을 이용한 휴먼 상호 행동의 인식에 대한 실험 및 분석을 3절에서 살펴보고, 4절에서 결론을 내린다.

## 2. 제안한 확률 네트워크 모델

서로 다른 상호 행동들 사이에 공유되는 부-상호 행동들이 존재할 때 각각의 상호 행동을 독립적으로 모델

링하는 것은 매우 비효율적이다. 또한, 상호 행동 패턴 전체를 하나의 모델로 표현할 경우, 상태수의 증가에 따라 모델의 복잡도는 기하급수적으로 증가한다. 복잡한 상호 행동을 작은 단위의 부-상호 행동으로 나누어서 모델링한 후, 원래의 상호 행동들을 이들 부-상호 행동 모델들의 네트워크로 표현하는 방법과 네트워크에서의 확률을 추론 알고리즘에 대해 살펴보자.

### 2.1 네트워크에서의 상호 행동 표현

방향성이 있는 그래프 또는 네트워크는 다양한 상호 행동을 부-상호 행동들의 관계 또는 순서를 표현하기에 매우 적합적인 도구이다. 예를 들어, 그림 1은 ‘따라가기+만나기+함께가기’, ‘따라가기+만나기+따로가기’, ‘접근하기+만나기+함께가기’, ‘접근하기+만나기+따로가기’, ‘접근하기+지나치기’의 5가지 상호 행동을 표현한 동적 확률 모델 네트워크이다. 그림에서  $B$ 와  $E$ 는 각각 상호 행동의 시작과 끝을 의미하며,  $I_1$ 와  $I_2$ 는 하나의 부-상호 행동에서 연속되는 다른 부-상호 행동으로의 전환을 의미한다.

### 2.2 동적 확률 모델 네트워크에서의 추론

본 논문에서는 상호 행동을 작은 단위의 부-상호 행동들의 시퀀스로 표현한다. 이로 인해 상호 행동 인식은 상호 행동에 포함되어 있는 부-상호 행동들의 시작점과 끝점을 찾는 것과 각 부-상호 행동들의 레이블을 분류하는 문제로 정의될 수 있다.  $G = G_1G_2\cdots G_K$ ,  $K \geq 1$ 을 부-상호 행동 시퀀스라 할 때, 이는 특징 벡터  $Y = Y_1Y_2\cdots Y_T$ 로부터 네트워크에서의 확률값을 최대로 하는  $G$ 를 추정하는 것이다. 여기서, 부-상호 행동의 개수  $K$ 는 사전에 알려져 있지 않다. 입력 특징 벡터 시퀀스에서  $K$ 개의 부-상호 행동에 해당하는 세그먼트  $V$ 를 다음과 같이 정의하자.

$$V = V_1V_2\cdots V_K \\ = v(1, t_1)v(t_1 + 1, t_2)\cdots v(t_{K-1} + 1, t_K)$$

여기서  $v(t_{k-1} + 1, t_k) = Y_{t_{k-1}+1}\cdots Y_{t_k}$ 이다. 네트워크 모델

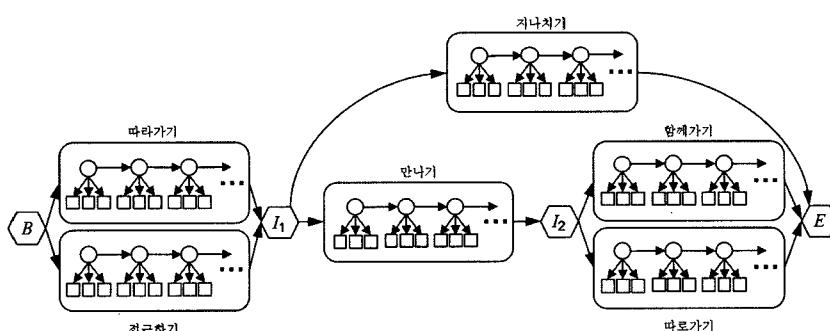


그림 1 부-상호 행동을 Multiple Observation HMM [6]으로 모델링한 상호 행동 네트워크 모델

을 이용한 상호 행동 인식 문제는 다음과 같이 수식화 될 수 있다.

$$\begin{aligned} P(Y | Network) &\triangleq \max_{K,G} P(Y, G | Network) \\ &= \max_{K,G,V} P(V, G | Network) \end{aligned} \quad (1)$$

이는 입력 시퀀스  $Y$ 가 주어졌을 때, 네트워크 모델에 서 최대 우도값을 출력하는 부-상호 행동의 개수  $K$ , 부-상호 행동 시퀀스  $G$ , 각 부-상호 행동에 해당하는 세그먼트  $V$ 를 동시에 추정하는 문제로 해석될 수 있다. 부-상호 행동간의 전이 확률이 동일하다고 가정하면 다음과 같이 전개된다.

$$\begin{aligned} P(V, G | Network) &= P(V | G)P(G | Network) \\ &\triangleq \prod_{k=1}^K P(V_k | G_k) \end{aligned} \quad (2)$$

부-상호 행동  $G_k$ 에서의 은닉 상태 시퀀스를  $S_k = s(t_{k-1}+1, t_k) = s_{t_{k-1}+1} \cdots s_{t_k}$ 로 정의하고, 식 (2)를 식 (1)에 대입하면 최종적으로 식 (3)을 얻을 수 있다.

$$\begin{aligned} P(Y | Network) &\triangleq \max_{K,V,G} P(V, G | Network) \\ &\triangleq \max_{K,V,G} \left[ \prod_{k=1}^K \max_{S_k} P(V_k, S_k | G_k) \right] \end{aligned} \quad (3)$$

이 식은 관측값  $Y$ 에 대한 네트워크에서의 우도값이 최대가 되기 위해서는 상호 행동을 구성하는 부-상호 행동 모델에서의 우도값 또한 최대가되어야 함을 의미한다. 이는 최적화 문제이며, 동적 프로그래밍(Dynamic Programming: DP) 기법을 이용하여 해결할 수 있다.

네트워크를 순회하면서 현재 노드를  $gr \in \{I_1, I_2, E\}$ , 바로 이전의 노드를  $gl$ 이라 하자. 이들 두 노드는 부-상호 행동 모델들로 연결된다.  $L(gl, gr)$ 을 두 네트워크 노드  $gl$ 과  $gr$  사이에 연결되어 있는 부-상호 행동 모델 집합이라 정의하자. 시간  $t$  까지의 부분 관측값에 대한 네트워크 노드  $gr$ 에서의 우도값은 다음과 같이 정의된다.

$$\Delta_t(gr) = P(Y_1 \cdots Y_t, s_1 \cdots s_t, s_t \rightarrow gr | Network) \quad (4)$$

식 (4)를 DP를 이용한 재귀식으로 표현하면 다음과 같으며, 이를 ‘전역 DP’라 한다.

$$\Delta_t(gr) = \max_{(gl, m) \text{ s.t. } m \in L(gl, gr)} \Delta_{t'}(gl) \times P(v(t'+1, t), s(t'+1, t) | m) \quad (5)$$

여기서,  $(gl, m)$ 은 네트워크 노드  $gl$ 에서  $gr$ 로 순회 할 때 부-상호 행동 모델  $m$ 을 거쳐간다는 의미이다. 식 (5)의 우변에 있는 두번째 항  $P(v(t'+1, t), s(t'+1, t) | m)$ 은 시간  $t'+1$ 부터  $t$  까지의 관측 시퀀스에 대한 부-상호 행동 모델  $m$ 에서의 최대 우도값을 의미한다. 부-

상호 행동  $m$ 에 해당하는 세그먼트의 시작점과 끝점은 확률적으로 결정된다.  $\Delta_t(gr)$ 의 최대 우도값을 생성한 부-상호 행동 모델의 레이블  $m$ 과 이전 네트워크 노드  $gl$ 을  $\Psi_t(gr)$ 에 저장하여 추론 알고리즘의 디코딩 단계에서 이용한다.

부-상호 행동 모델  $m$  내부에서 은닉 노드  $s_t$ 가 특정 상태  $i$  값을 가질 때의 우도값은 다음식과 같이 정의되며, 이를 ‘지역 DP’라 한다.

$$\begin{aligned} \delta_t^m(i) &= \Delta_t(gl) \times P(v(t'+1, t), s(t'+1, t-1), s_t = i | m) \\ &= \left\{ \max_j \delta_{t-1}^m(j) \times P_{s_t=i | s_{t-1}=j}^m \right\} \times P_{s_t=i}^m(Y_t) \end{aligned} \quad (6)$$

이때,  $\delta_t^m(i)$ 의 값을 결정하는 이전 상태 정보를  $\Psi_t^m(i)$ , 모델  $m$ 에 머무르는 시간 즉,  $\delta_t^m(i)$ 의 확률값을 최대로 하기 위해 시작점  $t'+1$ 부터 얼마의 시간이 지났는가를  $\varphi_t^m(i)$ 에 각각 저장한다. 이 변수들은 입력 시퀀스에 대한 추론이 끝난 후, 부-상호 행동들을 분할하는 단계에서의 연산을 쉽게 하기 위한 것들이며, Viterbi 알고리즘[7]에 기반을 둔 방법이다.

그러나 식 (6)을 계산할 때 모델  $m$ 의 첫번째 상태에 대해서는 네트워크 노드에서 전이가 일어날 경우와 모델  $m$  내부에서의 자기 전이(self-transition)가 일어날 때에 대한 두 가지 상황을 모두 고려하여야 하며, 다음의 식과 같이 계산된다.

$$\delta_t^m(1) = \max \left\{ \delta_{t-1}^m(1) P_{s_t=1 | s_{t-1}=1}^m, \Delta_t(gl) \times 1 \right\} \times P_{s_t=1}^m(Y_t) \quad (7)$$

이 식에서는 부-상호 행동 모델들에서의 상태 전이에 대해 ‘left-to-right’ 위상을 가정하였다.

식 (5), 식 (6), 식 (7)을 이용하여 입력 시퀀스에 대한 우도값을 계산한 후, 해당하는 상호 행동을 인식하기 위해서는 부-상호 행동 시퀀스 레이블을 결정해야 한다. 이는 네트워크 노드  $E$ 에서 최대 우도값을 출력한 부-상호 행동 모델  $m$ 을 결정한 후,  $\Psi$ 에 저장된 값들을 이용하여 역추적을 함으로써 가능하다.

### 3. 실험 결과 및 분석

이 절에서는 두 명의 휴먼 객체 사이에서 발생하는 상호 행동 인식 및 분석에 대해, 본 논문에서 제안하는 방법의 효율성을 실험을 통해 살펴본다.

#### 3.1 상호 행동 정의 및 데이터셋

본 논문의 실험에서는 다음의 5가지 상호 행동들을 고려한다: ‘따라가기+만나기+함께가기’ (상호 행동 1), ‘따라가기+만나기+따로가기’ (상호 행동 2), ‘접근하기+만나기+함께가기’ (상호 행동 3), ‘접근하기+만나기+따로가기’ (상호 행동 4), ‘접근하기+지나치기’ (상호 행동 5).

각 상호 행동마다 15개의 비디오 시퀀스를 캡쳐하여

총 75개의 시퀀스를 실험 데이터로 사용하였다. 실험에 사용된 비디오 시퀀스는 건물 2층에 설치된 JAI CV-S3300 카메라를 이용하여 30 fps의 속도로 캡처하였다. 이미지의 크기는 320×240이고, 색상은 24비트 컬러이다.

본 논문에서는 두 명의 휴면 객체 사이에서 일어나는 상호 행동을 모델링하는 것에 초점을 두고 있으므로, 휴면 객체의 검출과 추적은 수동으로 하였다. 부-상호 행동들의 표현은 기존의 여러 논문에서 이용된 동적 확률 모델을 이용한다. 본 논문에서는 Multiple Observation HMMs(MOHMMs)[6], Parallel HMMs(PaHMMs)[8], Coupled HMMs(CHMMs)[1], Factorial HMMs(FHMMs)[9], Observation Decomposed HMMs(ODHMMs)[2]를 이용한다. 부-상호 행동 모델의 학습 데이터 셋은 HMM[7]을 이용하여 상호 행동 시퀀스를 자동으로 분할하여 생성한다. 실험에 적용된 여러 모델의 학습 및 추론은 MATLAB으로 구현하였으며, K. Murphy의 BNT[10]를 이용하였다.

### 3.2 상호 행동 인식

5가지의 상호 행동에 대해 부-상호 행동들을 MOHMM으로 모델링하여 네트워크를 구성한 예가 그림 1에 나타나 있다. 상호 행동을 표현하기 위해 Liu와 Chua가 제안한 휴면의 이동 방위와 위치 변화에 강인한 특징[2]을 이용한다. 그러나 양자화에 따른 에러를 피하기 위해 연속값을 이용하며, 가우시안으로 모델링한다. 테스트 비디오 시퀀스로부터 추출된 특징 벡터 시퀀스  $Y$ 가 주어졌을 때, 이에 대한 우도값을 최대로 하는 부-상호 행동 모델 시퀀스는 식 (8)을 이용하여 검출한다.

$$\text{Interaction} = \arg \max_G P(Y, G | \text{Network}) \quad (8)$$

위 식에서  $Y = y_1y_2\cdots y_T$ 는 특징 벡터 시퀀스,  $G$ 은 네트워크에 포함되어 있는 부-상호 행동 모델의 시퀀스를 의미한다. 이는 2.2절에서 설명한 추론 알고리즘으로 계산될 수 있다. 그러나 식 (8)에서의 결과가 실제 상호 행동이 아닐 수도 있다. 왜냐하면, 그림 1에 정의된 상호 행동 네트워크에서의 순회는 ‘따라가기+지나치기’와 같은 정의되지 않은 상호 행동을 출력할 수도 있기 때문이다. 따라서 출력값의 적합성을 ‘검증’하는 단계가 필요하다. 만약 출력값이 부적합한 경우에는 이를 무시하고 다음의 최대 우도값을 생성한 부-상호 행동 시퀀스를 고려한다. 사실, 검증 단계는 네트워크에서의 추론에 직접적으로 적용될 수 있다. 즉, 네트워크 노드에 연결된 부-상호 행동 모델로 우도값을 전파할 때, 이 우도값을 생성한 이전 부-상호 행동 모델에서 다음 부-상호 행동 모델로의 이동 경로가 정의되어 있지 않은 경우, 무한히 작은 값을 전파함으로써 이 경로가 최종적으로 선택되는 것을 피할 수 있다.

### 3.2.1 제안하는 모델의 동작 분석

부-상호 행동 모델들의 네트워크로 상호 행동을 모델링하는 방법이 잘 동작하는지의 여부를 확인하기 위해 입력 특징 벡터 시퀀스에 대한 각 부-상호 행동 모델에서의 우도 변화 및 부-상호 행동 시퀀스 디코딩 결과를 확인한다. ‘접근하기+만나기+따로가기’ 상호 행동의 입력 시퀀스에 대한 부-상호 행동 모델들에서의 우도값 변화 및 상호 행동 인식 결과가 그림 2에 나타나 있다. 그럼에서 현재의 관측값에 해당하는 부-상호 행동 모델의 우도값이 다른 모델들 보다 높으며, 그 밖의 다른 모델들은 우도값이 상대적으로 낮다가 해당하는 관측값이 입력으로 들어오는 순간 급격히 증가하는 것을 알 수 있다. 이는 제안하는 상호 행동 네트워크 모델이 입력 시퀀스를 잘 표현하고 있다는 것을 보여준다. 그래프에서 서로 다른 부-상호 행동 모델들에 대한 우도값에 대한 기울기가 비슷하게 나타나는 것은 네트워크 순회에 있어 이전의 부-상호 행동 모델에서의 우도값이 다음 모델로 차례로 전파되었기 때문이다.

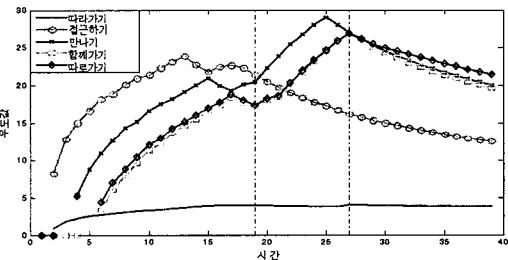


그림 2 '접근하기+만나기+따로가기' 입력 시퀀스에 대한 부-상호 행동 모델에서의 우도값 변화

### 3.2.2 기존 방법과의 인식 성능 비교

이 실험에서는 제안하는 방법과 하나의 동적 확률 모델로 하나의 상호 행동 패턴 전체를 모델링하는 기존 방법과의 인식 성능을 비교한다. 제안하는 방법은 복잡한 상호 행동을 작은 단위의 부-상호 행동으로 분할하여 모델링하였으므로 상태수를 2~3개로 설정하였고, 기존 방법에 대한 모델에서는 상태수를 5~9개로 설정하였다.

75개의 데이터 셋에서 임의로 선택한 20개의 상호 행동 데이터 셋으로 모델들을 학습하고, 나머지 55개로 학습된 모델의 인식 성능을 테스트를 하였다. 데이터 셋이 부족하기 때문에 인식 성능은 교차 검증 기법을 이용하여 평균값을 인식 성능으로 결정하였다. 표 1은 제안한 방법과 기존의 방법과의 인식 성능을 보여준다. 표에 보여진 바와 같이 상호 행동을 부-상호 행동 모델들의 네트워크로 구성하여 인식한 방법이 기존의 상호 행동 전

표 1 제안하는 방법과 기존 방법과의 인식 성능 비교

	MOHMM[6]	PaHMM[8]	CHMM[1]	FHMM[9]	ODHMM[2]
기존 방법	82.22%	68.89%	75.56%	66.67%	80%
제안한 방법	82.86%	77.09%	77.09%	80.02%	82.18%

체를 모델링하는 방법보다 성능이 우수함을 알 수 있다. 기존 방법에서의 성능이 떨어진 것은 학습 데이터가 부족한 것이 원인일 수 있다. 그러나, 이는 동일한 학습 데이터를 이용하여 더 높은 성능을 보인 제안한 방법의 우수성을 역으로 보여준다고 할 수 있다. 즉, 복잡한 상호 행동을 작은 단위의 부-상호 행동으로 분할하여 모델링함으로써 모델의 복잡도를 줄일 수 있으며, 부-상호 행동 모델들을 결합하여 복잡한 상호 행동을 표현할 수 있다는 것은 제안한 방법의 장점이다.

#### 4. 결론 및 향후 연구

본 논문에서는 이동 궤적 정보를 기반으로 두 명의 휴먼 객체 사이에서 발생 가능한 5가지 상호 행동에 대해, 이를 효율적으로 모델링하고 인식하는 방법을 제안하였다. 상호 행동의 동적 패턴 전체를 하나의 모델로 표현하기보다는, 여러 상호 행동들이 공유하는 작은 단위의 부-상호 행동들을 자동으로 분할하여, 이를 부-상호 행동 모델들의 순차적 연결 또는 네트워크로 표현하였다. 복잡한 상호 행동을 상대적으로 단순한 부-상호 행동 모델로 분할하여 모델링함으로써 계산 복잡도를 줄이고, 적은 양의 데이터로도 학습이 가능함을 실험을 통해 확인하였다.

#### 참 고 문 헌

- [1] N. Oliver, B. Rosario, and A. Pentland, "A Bayesian Computer Vision System for Modeling Human Interactions," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.22, no.8, pp.831-843, 2000.
- [2] X. Liu and C. Chua, "Multi-Agent Activity Recognition using Observation Decomposed Hidden Markov Models," *Image and Vision Computing*, vol.24, pp.166-175, 2006.
- [3] S. Hongeng, R. Nevatia, and F. Bremond, "Video-based Event Recognition: Activity Representation and Probabilistic Recognition Methods," *Computer Vision and Image Understanding*, vol.96, pp.129-162, 2004.
- [4] M. Ryoo and J. Aggarwal, "Semantic Representation and Recognition of Continued and Recursive Human Activities," *International Journal of Computer Vision*, vol.82, no.1 pp.1-24, 2009.
- [5] A. Hakeem and M. Shah, "Learning Detection and Representation of Multi-Agent Events in Videos,"

- Artificial Intelligence*, vol.171, pp.586-605, 2007.
- [6] T. Xiang and S. Gong, "Video Behavior Profiling for Anomaly Detection," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.30, no.5, pp.893-908, 2008.
  - [7] L. Rabiner, "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition," *Proceedings of the IEEE*, vol.77, pp.257-285, 1989.
  - [8] C. Vogler and D. Metaxas, "A Framework for Recognizing the Simultaneous Aspects of American Sign Language," *Computer Vision and Image Understanding*, vol.81, no.3, pp.358-384, 2001.
  - [9] Z. Ghahramani and M. Jordan, "Factorial Hidden Markov Model," *Machine Learning*, vol.29, no.2-3, pp.245-273, 1997.
  - [10] K. Murphy, *Dynamic Bayesian Network: Representation, Inference and Learning*, Ph.D. Dissertation, University of California, Berkeley, 2002.



석홍일

2004년 부경대학교 멀티미디어공학과(학사). 2007년 부경대학교 컴퓨터공학과(석사). 2008년~현재 고려대학교 컴퓨터학과 박사과정. 관심분야는 패턴인식, 논리-컴퓨터 인터페이스, 컴퓨터 시각 등

이성환

정보과학회논문지 : 소프트웨어 및 응용  
제 36 권 제 1 호 참조