

상황 전파 네트워크를 이용한 확률기반 상황생성 모델

Probability-Based Context-Generation Model with Situation Propagation Network

천 성 표¹, 김 성 신²

Cheon Seong-Pyo¹, Kim Sungshin²

Abstract A probability-based data generation is a typical context-generation method that is a not only simple and strong data generation method but also easy to update generation conditions. However, the probability-based context-generation method has been found its natural-born ambiguousness and confliction problems in generated context data. In order to compensate for the disadvantages of the probabilistic random data generation method, a situation propagation network is proposed in this paper. The situation propagating network is designed to update parameters of probability functions are included in probability-based data generation model. The proposed probability-based context-generation model generates two kinds of contexts: one is related to independent contexts, and the other is related to conditional contexts. The results of the proposed model are compared with the results of the probability-based model with respect to performance, reduction of ambiguity, and confliction.

Keywords: Probability-Based Context-Generation Model, Situation Propagation Network, Random Data Generation

1. 서 론

Schilit와 Theimer는 1994년 상황인식(Context-awareness)이라는 용어를 최초로 정의하였다[1]. 당시에는 상황인식을 응용 프로그램을 사용하는 환경이 변화되면, 새로운 환경의 변화를 반영해 줄 수 있도록 응용 프로그램을 개발해야 하고, 환경의 변화를 인지하는 것을 상황인식이라고 생각했다. A. K. Day는 상황을 사용자의 감정적 상태, 주의 초점, 위치와 방향, 날짜와 시간, 물체, 그리고 사람들까지 고려한 환경이라는 개념으로 정의하였다[2-3]. 그래서, 상황인식은 인간의 상황정보를 구체화시키거나 정의하는 기술로 발전하게 되었다. 최근 유비쿼터스 컴퓨팅을 위한 인프라 구축이 급격하게 진행되면서, 상황인식 컴퓨팅에 대한 관심과 필요성이 다시 한 번 부각되고 있다. 상황인식 기술은 일반적으로 동적으로 변화하는 상황을 관리하는 기술, 상황을 추론하는 기술, 그리고 상황을 모델링하는 기술로 분류된다[4]. 본 논문에서

는 상황 모델링 기술 가운데 상황 데이터 생성 모델을 제안한다. 확률 기반 상황 생성 모델은 생성하고자 하는 상황 별로 확률 함수를 정의해서 데이터를 생성하는 방법이기 때문에, 간단하면서도 실제 상황과 유사한 데이터를 생성할 수 있는 장점이 있지만, 확률 기반 데이터 생성법이 가진 모호성과 상황 충돌이라는 한계가 있다. 이 한계를 극복하기 위해서 본 논문에서는 상황 전파 네트워크를 제안해서 모호성과 상황 충돌을 줄였다. 제안한 상황 전파 네트워크를 이용한 확률 기반 상황 생성 모델을 단순히 동일한 확률 분포 함수만을 이용한 확률 기반 모델과 비교하면서 그 성능을 평가하였다.

2. 상황생성 모델

확률기반 상황생성 모델은 임의 데이터 생성 기법(Random data generation method)으로 각 상황 별로 발생 확률 분포 함수를 정의한 후, 특정 시간에 특정 상황을 발생시키는 방법이다. 따라서, 각 상황 별 확률 분포 함수만 정의하면 될 정도로 간단하면서도 강력한 데이터 생성법이다. 특히, 대부분의 데이터 생성법에 활용할 정도로 광범위하게 사용되며, 직관적이기 때문에 초기 상

Received : January 21th, 2009 Accepted : February 17th, 2009

※ 이 논문은 2009년 교육과학기술부로부터 지원받아 수행된 연구임
(지역거점연구단육성사업/차세대물류IT기술연구사업단)

¹ 부산대학교 BK21 영상IT 산학공동 사업단 박사후 연수연구원

² 부산대학교 전자전기공학부 부교수

황 생성 모델뿐만 아니라 현재도 꾸준히 활용되는 방법이다. 하지만, 확률기반 모델이 가진 태생적 한계가 있어 지속적으로 문제제기가 되어 왔다. 그것은 확률기반 모델에 순차적 상황 변화를 반영할 수 없기 때문에 생기는 것으로 생성된 상황이 전후 시점 또는 이전과 이후 상황을 기준으로 판단했을 때, 모호한 경우가 다분히 발생하고, 상황과 상황이 중복되거나 충돌하는 현상이 발생한다는 것이었다. 이를 극복하기 위해서 제안된 접근 방법이 온톨로지 모델(Ontology model)이다. 온톨로지 모델은 특정 상황이 발생하는 요건들을 미리 정의한 후, 해당 요건들이 만족될 때만 특정 상황이라고 판단하는 방법이다. 하지만, 인간이 실제로 상황을 판단할 때는 주관적인 경우가 많으며 항상 같은 상황이라고 판단하지 않기 때문에 상황의 변화를 자연스럽게 표현하기에는 부족하다. 다만, 한정된 상황들 가운데 특정 상황을 추론해야 하는 분야에서는 그 성능이 입증되고 있다. 온톨로지 모델은 고려해야 할 상황이 증가하거나 감소할 경우, 관련 요건들의 인과관계를 전체적으로 변화시켜야 하기 때문에 유연성과 확장성이 떨어지는 문제도 있다. 최근에는 온톨로지 모델의 단점을 보완하기 위해서 베이저안 네트워크(Bayesian Network)와 온톨로지 모델을 결합시켜 유연성과 추론 성능을 향상시키기 위한 시도가 이루어지고 있다[5-6]. 본 논문에서는 확률기반 모델의 태생적 한계를 극복하기 위해서 상황 전과 네트워크를 이용하여 상황들 간의 모호성과 충돌성을 극복하는 시도를 했다.

3. 순차적 상황 흐름

사람은 상황을 인식할 때, 인식하는 순간만을 고려하지 않는다. 따라서, 동일한 요건들이 갖추어진 경우에도 이전 시점의 상황이나 이후에 해야 하는 행동에 따라서 다른 상황이라고 인식하거나 의도적으로 다른 상황으로 만들기도 한다. 본 논문에서는 이러한 실제 상황인식의 복잡성을 고려하기 위해서 상황 전과 네트워크를 제안한다. 제안한 방법은 이전 시점에서 판단한 상황이 현재 시점에 미치는 영향을 반영하기 위한 것으로 순차 행동 의사결정과정에서 사용하는 마르코프 결정 모델을 적용한 것이다. 마르코프 결정 모델은 강화학습(Reinforcement Learning)에서 일반적으로 사용하는 방법이다[7-8]. 마르코프 결정 모델은 에이전트가 각 상태에 따라 취할 수 있는 행동이 정의된 상태-행위 천이 모델(State-action Transition Model)을 정의하고, 에이전트가 취할 수 있는 여러 조합의 상태-행위 경로들 가운데 가장 목적에 부합하는 경로를 학습한다. 각 상태에서 에이전트가 선택한 행위가 다음 상태를 결정하는데 영향을 미치게 되는데, 다음

상태를 결정하는 과정은 보상 함수(Reward function)를 통해서 목적에 가장 최적화된 정책의 상태-행위를 결정하도록 하는 학습하게 된다. 이것을 구체적으로 표현하면, 특정 초기 상태(Initial state) s 에서 다음 행위(action) a 를 선택하였을 때, 그 다음 상태 s' 로의 천이과정을 모델 $T(s, a, s')$ 로 정의하고, 각 상태-행위에 따른 보상 함수 $R(s)$ 값이 가장 큰 방향으로 최적화 정책 π^* (Optimal policy)를 결정하게 한다. 본 논문에서는 상태-행위 천이 모델 $T(s, a, s')$ 을 확률 모델로 간주하여 상황 전과 네트워크로 변형하였으며, 각 상황의 변화가 다음 상황에 미치는 영향을 기대값으로 표현하였고, 식 (1)로 정의한다.

$$T(s, a, s') = T_{ss'}^a = P\{s_{t+1} = s' | s_t = s, a_t = a\}$$

$$R(s, a, s') = R_{ss'}^a = E\{r_{t+1} | s_t = s, a_t = a, s_{t+1} = s'\}$$
(1)

여기서, $T_{ss'}^a$ 는 t 시점의 상태가 s 이고, 그 때 에이전트가 선택할 수 있는 행위 중에서 a 를 선택하였을 때, $t+1$ 시점에서 에이전트가 s' 이 될 확률을 말하며, $R_{ss'}^a$ 는 위와 동일한 상태천이과정에서 에이전트가 받는 보상에 대한 기대값이다. 본 논문에서는 최적화 정책 π^* 을 구하는 것이 목적이 아니라, $T_{ss'}^a$ 와 $R_{ss'}^a$ 를 각 상태-행위에 따라 갱신시켜서, 제안한 상황 모델에 일관성과 개연성을 부여하고자 한다. 특히, 본 논문에서의 $R_{ss'}^a$ 의 경우 사용자의 선호경향을 반영하기 위해서 사용자의 심리유형별 특징에 따라 다른 값을 가짐으로써 동적 서비스 선택이 가능하다. 그리고, 마르코프 특성(Markovian property)을 가정하여 순차적 상황 모델을 구했기 때문에, 상태-행위 천이과정의 시점에 대한 논란을 이전 시점으로 한정해 줌으로써, 전체 모델의 복잡성을 줄였다[9-10].

4. 상황 전과 네트워크를 활용한 확률기반 상황생성 모델

4.1 확률 분포 함수의 정의

상황인식은 너무나 추상적이고 개인적인 요소가 많기 때문에, 실생활의 모든 상황을 구체적으로 규정하는 것은 힘들다. 그래서, 상황인식에서 상황이란 특정 기술을 사용하는 목적에 부합하도록 필요한 상황을 별도로 정의해야 한다. 상황정보를 크게 분류하면 사용자 상황, 물리·환경적 상황, 컴퓨팅 시스템의 상황, 사용자-컴퓨터 상호 작용에 대한 상황, 기타 미분류 상황으로 나눌 수 있다[11]. Anders Kofod-Petersen은 사용자의 상황을 업무 상황, 사회적인 상황, 개인적인 상황, 시간-공간적인 상황, 환경적인 상황으로 정의하였다. 그리고, 개인적인 상황을 다시 생리적인 상황과 정신적인 상황으로 나누어

설명하고 있다[12]. 통용되는 상황 분류를 고려할 때 유비쿼터스 환경에서 서비스를 위한 상황은 사용자 상황, 생리적 상황, 물리·환경적 상황, 공간 상황, 시간 상황, 활동 상황 등으로 나눌 수 있다. 본 논문은 현재 사용자가 하고 있는 행동이나 상태를 말하는 사용자 상황을 가장 중요하게 생각한다. 구체적으로, 전체 11가지 사용자 상황을 고려하였으며, 11가지 사용자 상황을 8가지의 독립적인 상황 - 외출, 청소, 학습, 식사, 요리, 설거지, 목욕/세면, 그리고 수면 - 과 3가지의 이전 상황의 영향을 받는 조건부 상황 - 귀가, 휴식, 기상 - 으로 나누었다. 조건부 상황에서는 이전에 외출이라는 상황이 발생해야 귀가라는 상황이 선택될 확률이 높아져야 하고, 특정 임무를 수행해야 휴식을 취할 이유가 되며, 수면을 취해야 기상이 선택되는 것이 자연스럽게기 때문에 이들을 조건부 상황으로 분류하였다. 각 상황의 발생 확률을 주중과 주말로 나누어 표 1과 표 2에 정의하였다. 이해를 돕기 위해서, 그림 1과 그림 2에 각 상황 별 확률 분포 함수를 시간을 기준으로 도시하였다. 표 1과 표 2에서 정의

표 1. 주중의 상황 별 확률 분포 함수 예

	확률 분포 함수
외출	$f_{going\ out}(t) = \frac{1}{0.43\sqrt{2\pi}} \frac{1}{1 + \left \frac{t-13}{5} \right ^{2 \times 13}}$
청소	$f_{cleaning}(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(t-19)^2}{2 \times 0.3^2}}$
학습/독서	$f_{studying}(t) = \frac{1}{0.5\sqrt{2\pi}} \frac{1}{1 + \left \frac{t-20.5}{1.5} \right ^{2 \times 6}}$
식사	$f_{eating}(t) = \frac{1}{0.6\sqrt{2\pi}} e^{-\frac{(t-8)^2}{2 \times 0.3^2}} + \frac{1}{0.5\sqrt{2\pi}} e^{-\frac{(t-19)^2}{2 \times 0.5^2}}$
요리	$f_{cooking}(t) = \frac{1}{1.2\sqrt{2\pi}} e^{-\frac{(t-18)^2}{2 \times 0.5^2}}$
설거지	$f_{dishwashing}(t) = \frac{1}{1.5\sqrt{2\pi}} e^{-\frac{(t-19)^2}{2 \times 0.2^2}}$
목욕/세면	$f_{bathing}(t) = \frac{1}{0.4\sqrt{2\pi}} e^{-\frac{(t-7.2)^2}{2 \times 0.2^2}} + \frac{1}{0.6\sqrt{2\pi}} e^{-\frac{(t-19)^2}{2 \times 0.3^2}} + 0.1$
수면	$f_{sleeping}(t) = 1 - \left\{ \frac{1}{0.4\sqrt{2\pi}} \frac{1}{1 + \left \frac{t-15}{7} \right ^{2 \times 8}} + \frac{1}{3\sqrt{2\pi}} \frac{1}{1 + \left \frac{t-3.5}{3} \right ^{2 \times 4}} \right\}$
귀가	$f_{homecoming}(t) = \frac{1}{1.5\sqrt{2\pi}} e^{-\frac{(t-17.5)^2}{2 \times 0.5^2}}$
휴식	$f_{resting}(t) = \frac{1}{1.5\sqrt{2\pi}} \frac{1}{1 + \left \frac{t-20.5}{1.35} \right ^{2 \times 2.27}}$
기상	$f_{getting\ up}(t) = \frac{1}{1.5\sqrt{2\pi}} e^{-\frac{(t-8)^2}{2 \times 0.5^2}}$




그림 1. 시간에 따른 주중 상황 별 확률 분포 함수

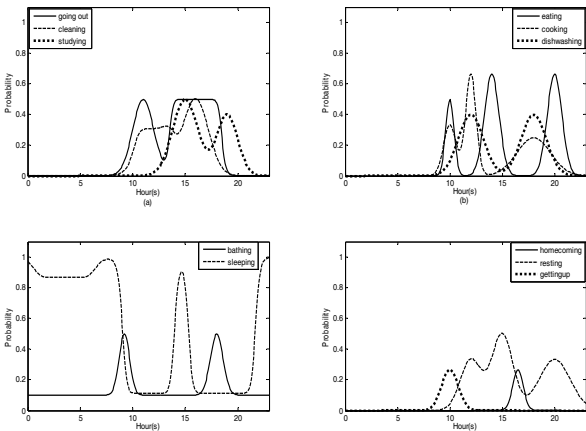


그림 2. 시간에 따른 주말 상황 별 확률 분포 함수

한 상황 별 확률 분포 함수는 사용자의 생활양식이나 습관에 따라 변경가능하며, 자신의 생활양식에 따라 독립적으로 정의가 가능하다. 본 논문에서는 가장 일상적인 생활양식을 가정하여 확률 분포 함수의 예를 제안하였으며, 이를 기준으로 모의실험을 수행하였다.

4.2 상황 전파 네트워크

상황생성 모델에서 이전 시점의 상황이나 이전 시점의 행동의 영향을 현재 시점에 반영하기 위해서 상황 전파 네트워크를 제안한다. 본 논문에서 제안한 상황 전파 네트워크는 그림 3에 나타내었다. 그림 3의 각 노드간에 설정되어 있는 가중치는 일상적 수준에서 설정한 것이다. 이 가중치가 특정 시점에 상황 별 확률 분포 함수값과 곱해져서 각 상황 별 선택 가능성이 결정된다. 따라서, 가중치의 영향도가 상황 별 확률 분포 함수보다 크지 않는 범위에서 결정하였다.

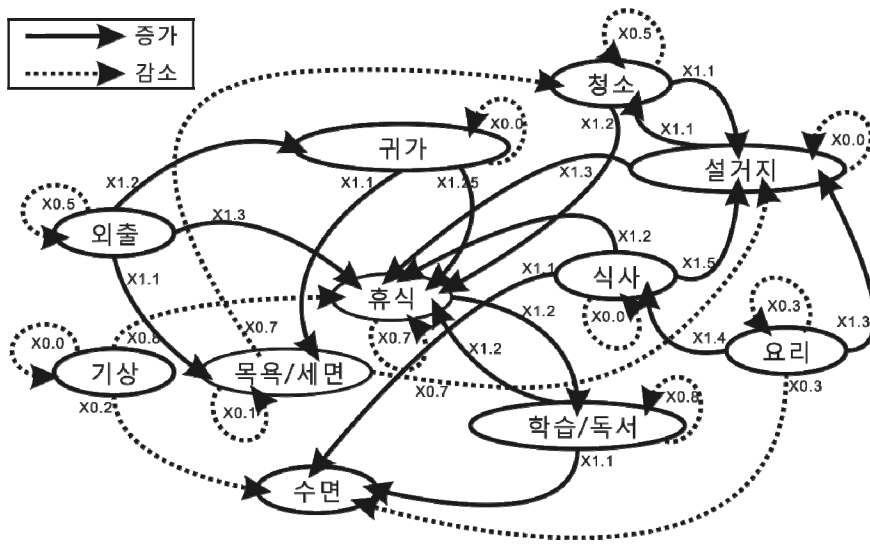


그림 3. 제안한 상황 전과 네트워크

표 2. 주말의 상황 별 확률 분포 함수 예

	확률 분포 함수
외출	$f_{goout}(t) = \frac{1}{0.8\sqrt{2\pi}} \left\{ e^{-\frac{(t-11)^2}{2 \times 1^2}} + \frac{1}{1 + \left \frac{t-16}{2.5} \right ^{2 \times 7}} \right\}$
청소	$f_{cleaning}(t) = \frac{1}{1.3\sqrt{2\pi}} \frac{1}{1 + \left \frac{t-12}{2} \right ^{2 \times 3}} + \frac{1}{0.8\sqrt{2\pi}} e^{-\frac{(t-16)^2}{2 \times 1.2^2}}$
학습/독서	$f_{eating}(t) = \frac{1}{0.8\sqrt{2\pi}} e^{-\frac{(t-10)^2}{2 \times 0.4^2}} + \frac{1}{0.6\sqrt{2\pi}} \left\{ e^{-\frac{(t-12)^2}{2 \times 0.5^2}} + e^{-\frac{(t-18)^2}{2 \times 1.6^2}} \right\}$
식사	$f_{eating}(t) = \frac{1}{0.8\sqrt{2\pi}} e^{-\frac{(t-10)^2}{2 \times 0.4^2}} + \frac{1}{0.6\sqrt{2\pi}} \left\{ e^{-\frac{(t-12)^2}{2 \times 0.5^2}} + e^{-\frac{(t-18)^2}{2 \times 1.6^2}} \right\}$
요리	$f_{cooking}(t) = \frac{1}{1.2\sqrt{2\pi}} e^{-\frac{(t-10)^2}{2 \times 0.6^2}} + \frac{1}{0.6\sqrt{2\pi}} e^{-\frac{(t-12)^2}{2 \times 0.5^2}} + \frac{1}{1.6\sqrt{2\pi}} e^{-\frac{(t-18)^2}{2 \times 1.6^2}}$
설거지	$f_{dishwashing}(t) = \frac{1}{\sqrt{2\pi}} \left\{ e^{-\frac{(t-12)^2}{2 \times 1.2^2}} + e^{-\frac{(t-18)^2}{2 \times 1.2^2}} \right\}$
목욕/세면	$f_{bathing}(t) = \frac{1}{\sqrt{2\pi}} \left\{ e^{-\frac{(t-9.2)^2}{2 \times 0.5^2}} + e^{-\frac{(t-18)^2}{2 \times 0.6^2}} \right\} + 0.1$
수면	$f_{sleeping}(t) = 1 - \left\{ \frac{1}{0.45\sqrt{2\pi}} \left[\frac{1}{1 + \left \frac{t-11.5}{2.5} \right ^{2 \times 6}} + \frac{1}{1 + \left \frac{t-18.5}{3.2} \right ^{2 \times 8}} \right] + \frac{1}{0.3\sqrt{2\pi}} \frac{1}{1 + \left \frac{t-3.5}{3} \right ^{2 \times 4}} \right\}$
귀가	$f_{homecoming}(t) = \frac{1}{1.5\sqrt{2\pi}} e^{-\frac{(t-16.5)^2}{2 \times 0.5^2}}$
휴식	$f_{resting}(t) = \frac{1}{1.2\sqrt{2\pi}} e^{-\frac{(t-12)^2}{2 \times 1.0^2}} + \frac{1}{0.8\sqrt{2\pi}} e^{-\frac{(t-16)^2}{2 \times 1.0^2}} + \frac{1}{1.2\sqrt{2\pi}} e^{-\frac{(t-20)^2}{2 \times 1.5^2}}$
기상	$f_{gettingup}(t) = \frac{1}{1.5\sqrt{2\pi}} e^{-\frac{(t-10)^2}{2 \times 0.8^2}}$

5. 모의실험 및 성능평가

제안한 모델의 성능을 확인하기 위해서 본 논문에서는 상황 전과 네트워크를 거치지 않는 전형적인 확률기반 상황 생성 모델과 상황 전과 네트워크와 확률기반 상황 생성 모델이 결합된 모델을 모의실험을 통해서 비교해 보았다. 확률기반 모델에서 생성된 상황의 임의성을 배제하기 위해서, 모의실험의 상황 생성 기간을 1시간 간격으로 총 1년으로 하였다. 매 시간 데이터를 생성하면서 1년 동안의 기간을 설정한 것은 모의실험 결과에 임의 데이터 생성법이 가진 우연성을 배제하고 모의실험의 재현성을 높이기 위한 것이다. 확률 분포 함수를 주중과 주말로 나누어서 별도로 정의하기는 했지만, 두 모델에 대한 모의실험 조건이 일치하므로 주중과 주말 생성 상황 데이터에 대한 분석은 생략하였다. 또한, 독립적 상황의 경우 미리 정의된 확률 분포 함수에 의해서 생성되기 때문에 상황의 모호성과 충돌성의 비교는 생략하였고, 상황 전과 네트워크의 영향을 크게 받는 조건부 상황에 대해서만 평가했다. 모의실험의 결과를 표 3과 표 4에 각각 나타내었다. 표 3은 생성 데이터의 모호성을 평가하기 위한 것으로 동일 상황이 연속해서 반복적으로 생성되는 경우를 정리한 것이다. 표 3에 보이는 것처럼 확률기반 모델은 총 72회의 반복적 상황이 생성

표 3. 조건부 상황의 반복 생성 횟수

횟수	확률기반 모델			상황 전과 네트워크와 확률기반 모델		
	귀가	휴식	기상	귀가	휴식	기상
횟수	10	62	0	2	3	2

표 4. 조건부 상황의 상황 충돌 횟수 분석

	확률기반 모델			상황 전과 네트워크와 확률기반 모델		
	귀가	휴식	기상	귀가	휴식	기상
외출	7	3	0	3	2	0
귀가	0	0	0	0	0	0
휴식	0	14	0	0	3	0
청소	1	0	0	0	5	0
학습	0	3	0	2	2	0
기상	0	0	0	0	0	0
수면	0	23	16	1	3	0
식사	0	0	0	1	1	0
요리	1	1	0	0	1	0
설거지	0	1	0	0	1	0
목욕	0	2	0	1	1	2
소계	9	47	16	8	19	2
계	130	415	82	135	227	67
비율	6.9%	11.3%	19.5%	5.9%	8.4%	3.0%

된 반면, 상황전과 네트워크를 통과시켰을 경우는 단 7 회만 반복적 상황이 생성되었다. 표 4는 상황의 충돌성을 평가하기 위한 것이다. 본 논문에서 상황의 충돌성은 이전 시점($t-1$)과 이후 시점($t+1$)의 상황이 동일한데, 현재 시점(t)에서 조건부 상황이 선택되는 경우로 가정하였다. 예를 들면, 이전 시점($t-1$)과 이후 시점($t+1$)의 상황이 둘 다 '요리' 인데, 현재 시점(t)에서 '외출'이 선택되는 경우를 상황 충돌이라고 판단했다. 표 4를 다시 한 번 살펴 보면, 귀가의 경우 확률기반 모델이 130회 선택한 가운데 9회 충돌하였고, 상황 전과 네트워크를 통과시켰을 때 135회 선택한 가운데 8회 충돌하였지만, 기상의 경우 확률기반 모델이 82회 가운데 16회, 상황 전과 네트워크를 통과시켰을 때 67회 가운데 2회 충돌하였다. 사실 가장 많은 상황이 발생하는 경우가 휴식인데, 휴식의 경우 확률기반 모델이 무려 415회 가운데 47회 충돌 상황이 발생한 것에 비해 상황 전과 네트워크를 통과시켰을 때 227회 가운데 19회만 발생하였다. 종합적으로 모호성과 충돌성을 기준으로 두 모델을 평가하면, 상황 전과 네트워크를 통과시켰을 때, 귀가의 경우 1%, 휴식의 경우 2.9%, 그리고 기상의 경우 16.5%가 줄어들었음을 확인할 수 있다. 귀가의 경우 상황 전과 네트워크의 영향이 그다지 미치지 않는 것을 확인할 수 있는데, 귀가의 경우 외출($t-1$)과 외출($t+1$) 사이에 선택될 경우가 주요한 상황 충돌이라고 볼 수 있고, 그 외의 경우는 임의 데이터 생성법에 의한 충돌이라고 볼 수 있다. 실제 표 4를 보면,

외출과 귀가의 충돌은 확률기반 모델의 경우 7회에서, 상황 전과 네트워크를 통과 시켰을 경우는 3회로 감소했음을 확인할 수 있다.

6. 결 론

유비쿼터스 컴퓨팅이 발전함에 따라 상황인식과 관련된 기술 역시 비약적으로 발전하고 있다. 본 논문은 확률기반 모델과 온톨로지 모델이 가진 태생적 한계를 극복한 향상된 상황 생성 모델을 제안하였다. 제안한 모델은 확률기반 모델의 단순함과 강력함 그리고 직관적 모델이 가능한 장점은 최대한 살면서, 온톨로지 모델이 갖지 못한 유연성과 확장성을 추구하였다. 제안한 모델의 성능은 모의실험을 통해서 확인하였고, 성능 평가는 상황의 모호성과 충돌성을 얼마나 감소시켰는가로 하였다. 모의실험결과 상황 전과 네트워크를 통과시켰을 때, 단순한 확률기반 모델을 사용했을 때 보다 성능이 향상되었음을 확인할 수 있었다.

참 고 문 헌

- [1] B. N. Schilit and M. M. Theimer, "Disseminating Active Map Information to Mobile Hosts," *IEEE Network*, vol. 8, issue 5, pp. 22-32, Sep/Oct 1994.
- [2] A. K. Dey, *Context-Aware Computing: The CyberDesk Project*, AAAI 1998 Spring Symposium on Intelligent Environments, Technical Report SS-98-02, 1998, pp. 51-54.
- [3] A. K. Dey, G. D. Abowd, and D. Salber, "A Context based Infrastructure for Smart Environments," *Proc. Of the 1st Int' Workshop on Managing Interactions in Smart Environments (MANSE '99)*, pp. 114-128, Apr. 1999.
- [4] J. Pascoe, N. Pyan, and D. Morse, "Issues in Developing Context-Aware Computing," *LNCS*, vol. 1707, pp. 208-221, 1999.
- [5] 정현만, "유비쿼터스 컴퓨팅 환경에서의 온톨로지 기반 상황 인식 미들웨어," 한국컴퓨터정보학회 2006년 하계학술발표논문집&학회지, 제14권 1호, pp. 165-173, 2006.
- [6] 정현만, 이정현, "유비쿼터스 컴퓨터 환경에서의 상황 인식을 위한 확률 확장 온톨로지 모델," 한국컴퓨터정보학회논문지, 제11권 3호, pp.239-248, 2006.
- [7] R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*. MIT Press, MA: Cambridge, 1998.

- [8] T. Mitchell, *Machine Learning*. McGraw Hill International Edition, 1997.
- [9] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*. Springer Series in Statistics, Springer, 2001.
- [10] A. Doucet, N. Freitas, and N. Gordon, *Sequential Monte Carlo Methods in Practice*. Statistics for Engineering and Information Science, Springer, 2001.
- [11] 임신영, 허재두, “상황인식 컴퓨팅 응용 기술 동향,” 한국전자통신연구원, 전자통신동향분석, 제19권 5호, 2004.
- [12] Anders Kofod-Petersen, *A Case-Based Approach to Realising Ambient Intelligence among Agents*, Thesis for the degree doctor scientiarum, 2007.



천 성 표

1999 부산대학교 전기공학과 (공학사)
 2001 부산대학교 전기공학과 (공학석사)
 2004 LG CNS 근무

2009 부산대학교 전기공학과(공학박사)
 관심분야: Machine Learning, Bayesian Network, Neural Network



김 성 신

1986 연세대학교 전기공학과 (공학석사)
 1996 Georgia Institute of Technology 전기공학과 (공학박사)

1998~현재 부산대학교 전자전기공학부 부교수
 관심분야: 지능시스템, 학습제어, 소프트웨어, 데이터 마이닝