

# 유비쿼터스 홈 네트워크에서 사용자 프로파일에 기반한 비정상 행동 분석 알고리즘

강원준<sup>o</sup> 신동규 신동일

세종대학교

wonjoon@gce.sejong.ac.kr, shindk@sejong.ac.kr, dshin@sejong.ac.kr

## Abnormal Behavior Analysis Algorithm Development Based on User Profile in Ubiquitous Home Network

Wonjoon Kang<sup>o</sup> Shin Dongkyoo Shin Dongil

Department of Computer Engineering, Sejong University

### 요 약

본 논문은 본 연구팀이 행동패턴 분석을 위하여 개발한 BPP(Behavior Pattern Prediction) 알고리즘의 가중치(weight) 속성을 객관적으로 수식화 하는 방법과 가중치와 행동 프로파일을 이용하여 정상/비정상 행동여부를 판단하는 ABA(Abnormal Behavior Analysis) 알고리즘을 제안한다. 가중치는 거주자의 방과 행동 사이의 연관성을 나타내며 가중치가 제한된 범위 내에서 증가할수록 행동에 대한 관심이 크다. 구축한 사용자 프로파일의 주요 구성 요소로는 행동이 지속된 시간 과 행동 발생 횟수이다. ABA 알고리즘은 가중치와 행동 발생 횟수, 행동 지속시간과의 상관분석 결과를 참조 하였으며, 이산 가중치 데이터를 분석하여 비정상적인 행동을 탐지한다.

### 1. 서 론

홈 네트워크는 유무선 네트워크를 기반으로 가정 내의 다양한 가전기기 및 센서를 구성하여 다양한 서비스의 제공이 가능하도록 한다. 그리고 언제 어디서나 안전하고 자동화 서비스의 제공이 가능하며 홈 서버를 통해 집안 전체의 관리가 가능한 환경을 의미한다[1][2]. 최근 가정내의 가전기기들을 유무선 네트워크에 연결하여 지능화된 서비스를 제공하는 지능형 홈 네트워크에 많은 관심과 연구개발이 진행되고 있다[3,4]. 지능형 홈 네트워크 구성을 위해서는 사용자의 맥내 기기에 대한 개입을 최소화하면서 사용자 개인의 특성에 맞추어진 서비스를 제공해야 한다. 이를 위해서는 사용자에 대한 정보와 환경 데이터를 수집, 관리, 가공하는 시스템이 필요하다. 즉, 사용자 상황의 실시간 데이터 수집을 위한 무선 센서 기술과 사용자의 가전에 대한 설정 값 및 구동 상황에 맞는 선호도를 수집, 관리, 가공할 수 있는 서버가 필요하다[5].

본 논문에서는 방과 사용자의 행동 사이의 관계를 객관적으로 판단하기 위해서 가중치(weight)를 부여하여, 사용자가 머물렀던 방에서 발생한 행동에 대한 관심을 수식으로 나타내는 방법을 제안한다. 그리고 가중치와 중요 프로파일 속성(행동 발생 횟수, 행동 지속 시간)간의 상관분석 방법을 이용하여, Pearson

상관계수를 분석한다. 가중치와 프로파일 중요 속성간의 상관관계를 참조하여 ABA 알고리즘을 제안한다. ABA 알고리즘은 가중치와 사용자 행동 프로파일을 이용하여 예외적인 행동을 검색 하고, 정상/비정상적인 행동 여부를 판단한다. 본 연구의 실험 방법으로는, “MIT Placelab”에서 “활동 인지 시스템(Activity Recognition System) [6]” 구현 결과로 측정된 행동 패턴 데이터를 본 논문에서 제안한 가중치 계산식과 ABA 알고리즘에 적용하여 비정상적인 행동을 분석한다.

본 논문의 구성은 다음과 같다. 2장에서는 비정상 행동 예측 시스템 관련연구를 살펴보고, 3장에서는 ABA(Abnormal Behavior Analysis) 알고리즘을 기술하며, 4장에서는 실험 및 결과를 설명한다. 마지막으로 5장에서는 결론 및 향후 연구 방향에 대해서 논한다.

### 2. 관련 연구

SA-RFID 시스템 (Situation-Aware RFID System)은 유비쿼터스 컴퓨팅 환경에 적합한 RFID 시스템으로서[7], 태그로부터 획득된 정보를 Situation-Aware를 통해 종합 판단하여 사용자에게 맞는 서비스를 제공하는 기능을 한다.

#### 2.1. 비정상 행동 예측 시스템 모델

SA-RFID 시스템을 이용하여 비정상 행동을 예측하는 체계의 작동 매커니즘은 그림 1과 같다. RFID-T로부터

\* 본 연구는 문화체육관광부 및 한국콘텐츠진흥원의 2009년도 문화콘텐츠산업기술지원사업의 연구결과로 수행되었음

수집 가능한 위치정보와, 태그를 수집할 때 얻을 수 있는 시간정보를 RFID-R은 지역 내 정보를 통합 수집하는 DPS로 전송한다. 제한된 장소 내의 유저들로부터 정보를 제공받은 DPS는 시간에 따른 일반유저들의 위치정보를 암호화해서 RFID-R에게 다시 전송한다. 이렇게 전송된  $I_{all}$ 를 RFID-R 내부의 SA Middleware에서 자신의 정보와 비교 판단하여 최종 산출물인  $I_p$ 를 사용자에게 제공하게 된다.  $I_p$ 가 제공하는 주변의 비정상 행동 예측 정보를 통해 사용자는 공공장소 같은 제한된 장소에서 자신의 안전을 보장받을 수 있게 된다 [7].

RFID-T로부터 수집 가능한 위치정보와 태그를 수집할 때 얻을 수 있는 시간정보를, RFID-R은 지역내 정보를 통합 수집하는 DPS로 전송한다. 제한된 장소 내의 유저들로부터 정보를 제공받은 DPS는 시간에 따른 일반유저들의 위치정보를 암호화해서 RFID-R에게 다시 전송한다. 이렇게 전송된  $I_{all}$ 를 RFID-R 내부의 SA Middleware에서 자신의 정보와 비교 판단하여 최종 산출물인  $I_p$ 를 사용자에게 제공하게 된다.  $I_p$ 가 제공하는 주변의 비정상 행동 예측 정보를 통해 사용자는 공공장소 같은 제한된 장소에서 자신의 안전을 보장받을 수 있게 된다 [9].




그림 1. 비정상 행동 예측 시스템 모델 시나리오

### 3. ABA(Abnormal Behavior) 알고리즘

#### 3.1. BPP(Behavior Pattern Prediction)알고리즘 설명

본 연구팀이 행동패턴 분석 및 예측 연구에서 개발한 BPP 알고리즘은 사용자가 어느 방에 자주 방문하고, 어떤 행동을 자주 반복 하는지 파악을 하여 사용자 프로파일을 구축한다. 또 한, 사용자가 머물렀던 방과 행동에 대한 관심을 표현하기 위해 거주지 사용자가 직접 가중치 (*weight*) 를 부여 하며, 수정이 가능하다. 가중치 (*weight*) 는,  $w(Act_i, Rm_j)$ , ( $0 \leq w(Act_i, Rm_j) \leq 1$ ) 으로 정의한다. 그리고 사용자 프로파일을 구축하기 위해서 *Count Profile* 과 *Duration Profile* 을 제안 하였다. *Count Profile* 이란 방에서 사용자가 한 행동의 횟수에 관한 프로파일 (*Profile*) 이며  $CntP(i)$  으로 표현한다.

#### 2.2. 비정상 행동 예측 시스템 설계.

SA-RFID 시스템의 여러 가지 type[8]중에 비정상 행동 예측 시스템에 적용되는 아키텍처는, 새로운 구성 요소의 추가 없이 기존 RFID 시스템의 개념을 유지하면서 구성요소인 RFID 리더기의 기능을 확장할 수 있는 SA-RFID reader기반 시스템을 변형한 형태이다. 따라서 제안하는 아키텍처는 SA-RFID 시스템으로의 개량 및 활용이 용이하며, 기존의 센서 네트워크 기반의 아키텍처들에 비해 시스템의 복잡도가 높지 않다는 장점을 지닌다. 또한 RFID 태그 정보 판독과 단말내의 상황 정보를 하나의 구성요소가 수집함으로써 채널의 일관성을 유지할 수 있다는 장점도 지닌다.

$$CntP(i) = \frac{\sum_j (count(Act_i) * w_i(Act_i, Rm_j))}{\sum_k count(Rm_k)} \quad (수식 1)$$

$Act_i$  : Action ID,  $Rm_j$  : Room ID

$\sum_k count(Rm_k)$  : 방( $Rm_k$ )에 출입한 횟수의 합

$count(Act_i)$  : 행동( $Act_i$ ) 발생 횟수

$w_i(Act_i, Rm_j)$  : 행동( $Act_i$ ) 과 방( $Rm_j$ ) 사이의 연관성

*Duration Profile* 이란 방에서 사용자가 한 행동의 소요시간에 관한 프로파일(Profile) 이다. *Count Profile* 을  $DurP(i)$  으로 표현한다.

$$DurP(i) = \frac{\sum_j (duration(Act_i) * w_i(Act_i, Rm_j))}{\sum_k duration(Rm_k)} \quad (수식 2)$$

$\sum_k duration(Rm_k)$  : 방( $Rm_k$ )에 머문 시간의 합

$duration(Act_i)$  : 행동( $Act_i$ ) 이 지속된 시간

시간과 행동에 관한 프로파일을 이용하여 변수  $x_i$  를 제안한다.

$$x_i = a * DurP(i) + b * CntP(i),$$




그림 2. 변형된 SA-RFID reader 기반 시스템 아키텍처

반면, 이 아키텍처는 RFID 리더기와 DPS간의 원격 통신 기능, 태그 정보 수집 및 단말기내의 정보 수집 기능 등의 추가적인 기능들을 지녀야 한다. 따라서 다른 아키텍처들에 비해 RFID 리더기의 오버헤드가 크다는 단점을 지닌다.

#### 2.3. 비정상 행동 예측 시스템 시나리오

$$\text{where}(a + b) = 1 \quad (\text{수식 } 3)$$

수식 3 에서 상수  $a$  와  $b$  는 *Count Profile* 과 *Duration Profile* 사이에서 상대적인 중요도를 나타낸 것이다. 홈 네트워크 상에서 *User Profile* 은 오직 어떤 시점에서 유효하다. 그러므로 *Time Stamp* 정보와 변수  $x_i$  를 이용하여 상대적인 사용자의 흥미변화를 관찰하여 다음 행동을 예측한다.

표 1. 방에 방문한 횟수, *Time Stamp* 와 가중치

User_ID	count(Rm <sub>1</sub> )	Time Stamp	w <sub>1</sub>	w <sub>2</sub>	w <sub>3</sub>	w <sub>4</sub>
1	2	05.09.2009	0.5	0.2	0.1	0.5
		16:25:30				
2	3	05.09.2009	0.2	0.6	0.5	0.7
		15:10:50				

표 1 은 방에 방문한 횟수  $\text{count}(Rm_1)$  와 방문한 시간 (*Time Stamp*), 그리고 방에서 발생한 행동에 대한 가중치 ( $w_i$ ) 를 나타낸다. 그림 2 는 시간대 별로 사용자의 행동 패턴과 관심도의 변화를 나타낸다. 사용자 프로파일로 얻어진  $x_2$  데이터는  $t_0 \sim t_3$  시간대 에서  $t_1$  시간에 가장 높은 값을 나타낸다. 그리고 시간대 별 사용자 행동 패턴 데이터를 축적하여 사용자의 다음 행동을 예측 하는 알고리즘을 제안 했다.




그림 3. 시간대 별 사용자 행동 패턴 분석 그래프

### 3.2. 사용자 프로파일 데이터

본 논문에서는 “MIT Placelab”에서 “활동 인지 시스템(Activity Recognition System)” 구축을 위해서 설치한 “state-change sensor” 로 부터 저장된 행동이 시작하고 종료된 시간과, 센서가 설치된 장소 데이터를 사용했다. 행동 Label sampling은 ESM(Experience Sampling Method)방식을 사용하여 행동에 대한 ID를 부여 했다. 센서가 설치된 장소는 가전제품(TV, DVD, stereos, refrigerator, freezer, microwave, washing machine, lamp, light switch, oven, burner, coffee machine, stoves)이나 가구(Cabinet, Container, Medicine Cabinet, windows, doors) 이다. 표 2은 본 논문에서 사용한 원본 데이터 이며, 행동 별로 가전제품이나 가구를 사용한 시간정보와 센서가 설치된 장소 데이터가 저장되어 있다.

표 2. state-change sensor 와 ESM을 이용한 데이터 Type

Activity	sensor ID	day	activation time	deactivation time	duration (sec)	room (opt)	object type (opt)
Preparing breakfast	PDA	12/1/02	08:23:01		10 min		
	23	12/1/02	08:23:03	08:23:07	4	kitchen	drawer
	18	12/1/02	08:23:09	08:23:17	8	kitchen	cabinet
	89	12/1/02	08:24:49	08:24:59	10	kitchen	fridge door
	⋮		(many readings)				

본 논문은 ESM을 사용하여 Labeling 된 행동을 Main/Sub action으로 분류를 한다. 표 3은, 부엌에서 발생할 수 있는 Main action를 정의한 결과이며, 부엌에 설치된 센서 에서 측정된 행동 데이터를 Sub action 으로 분류 하여, 본 논문에서 제안한 가중치 수식과 ABA 알고리즘에 적용 한다.

표 3. Main/Sub Action Dataset

Main action	Sub action	Code	Location
Preparing breakfast	Burner	131	Kitchen
	Coffee machine	133	Kitchen
	Oven	138	Kitchen
	Toaster	139	Kitchen
	Refrigerator	137	Kitchen
	Freezer	144	Kitchen
	Microwave	143	Kitchen
Bathing Toileting	Sink faucet - hot	68	Kitchen
	Sink faucet - cold	88	Kitchen
	Shower faucet	93	Kitchen
	Exhaust Fan	96	Kitchen

### 3.3. 가중치 수식화

이전 행동패턴 연구에서 개발한 BPP(Behavior Pattern Prediction) 알고리즘은 거주자의 주관적인 판단으로 거주지 사용자의 방과 방에서 발생한 행동 사이의 연관성을 가중치로서 상대적인 변수를 지정하였다. 그 결과, 객관적인 프로파일을 구축하기가 어려우며, 행동 패턴 예측 정확도가 낮다. 본 논문에서는 거주지 사용자의 방과 방에서 발생한 행동 사이의 연관성을 객관적으로 수식화 하는 방법을 수식 4와 같이 제안한다.

$$w_i(SAct_i, Rm_j) = a \frac{\sum_i cnt(SAct_i)}{\sum_k cnt(SAct_k)} + (1 - a) \frac{\sum_i durn(SAct_i)}{durn(MAct_k)} \quad (\text{수식 } 4)$$

$SAct_i$  : Sub Action ID ,  $Rm_j$  : Room ID

$MAct_k$  : Main Action ID

$a$  : 행동 횟수와 행동 지속 시간의 상대적인 중요도 ( $0 < a < 1$ )

$w_i(SAct_i, Rm_j)$  : 행동( $SAct_i$ ) 과 방( $Rm_j$ ) 사이의 연관성

$\sum_k cnt(SAct_k)$  : 방( $Rm_j$ )에서 전체 행동 횟수의 합

$\sum_i count(SAct_i)$  : 방( $Rm_j$ )에서 행동 ( $SAct_i$ ) 횟수의 합

$durn(MAct_k)$  : 방( $Rm_j$ )에서 행동 ( $MAct_k$ ) 지속 시간

$\sum_i durn(SAct_i)$  : 방( $Rm_j$ )에서 행동 ( $SAct_i$ ) 지속 시간의 합

$0 \leq w \leq 1$  범위 내에서 가중치가 클수록 사용자의 행동과 방 사이의 연관성이 높고, 행동에 대한 흥미가 많다는 것을 나타낸다. 가중치 계산식에서 행동 횟수에 대한 수식은 구하고자 하는 Sub action 횟수를 Main Action에서 발생한 모든 Sub action의 합으로 나누어 계산하므로 행동 횟수에 관한 계산 결과는 0 과 1 사이의 값을 갖는다. 그러나, 행동 발생 시간 수식에서 구하고자 하는 Sub action의 행동 발생 시간은 Main action이 종료된 시점에도 지속될 수 있으므로, 행동 발생 시간 계산 결과가 1 이상의 값을 가질 수 있다.

표 4. 가중치 계산 결과 Dataset

Mainaction	Date	Start time	End time	Duration(sec)	Room
Preparing breakfast	04/10/2003	AM 9:21:30	9:30:57	567	Kitchen
Subaction	Code	Duration(sec)	Count	Room	w
Toaster	131	7	2	Kitchen	0.2123
Coffee machine	119	77	1	Kitchen	0.2358
Cabinet	59	2	1	Kitchen	0.1035
Cabinet	73	43	1	Kitchen	0.1758
Light switch	105	11927	1	Kitchen	21.1353
Cabinet	55	1	1	Kitchen	0.1018
Drawer	84	3	1	Kitchen	0.1053
Dishwasher	70	5356	1	Kitchen	9.5462
Refrigerator	91	13	1	Kitchen	0.1229
Freezer	137	5892	1	Kitchen	10.4951

위와 같은 행동 프로파일 데이터에 근거하여 표 4와 같이, 가중치는 1보다 큰 결과가 나올 수 있으며, 최대 약 400000의 값을 가진다. 표 4의 가중치 계산 결과는 객관적으로 가중치와 행동 발생 횟수, 행동 지속 시간 사이의 관계를 파악하기 위해서, 행동 횟수와 행동 지속 시간의 상대적인 중요도 변수  $a$ 를 고려하지 않았다.

### 3.4. 비정상 행동 분석

사용자 행동 프로파일 데이터의 중요 속성은 행동 발생 횟수와 행동 지속 시간이다. 가중치가 어떠한 행동 프로파일 데이터와 관련이 있는지 분석을 하기 위해서 가중치와 사용자의 행동 프로파일 속성 사이의 산점도를 그려서 표본들의 분포를 파악한다.




그림 4. w, Count, Duration 행렬 산점도

그림 4는 가중치와 행동 발생 횟수, 행동 지속 시간 사이의 행렬 산점도를 나타내고 있으며, 가중치와 행동 지속 시간은 대략 선형적인 관계를 나타내고 있으므로 상관분석 방법을 이용하여, 가중치와 행동 지속 시간 사이의 연관성을 살펴본다. 표 5는 가중치와 두 변수(행동 발생 횟수, 행동 지속 시간) 사이의 단순상관분석을 적용한 결과를 나타낸다. 가중치(w)와 행동 지속 시간(Duration)사이의 Pearson 상관계수는 0.802이며, 유의 확률은 0으로써 유의수준 0.01보다 작으므로 강한 양의 상관관계에 있다. 그러나 가중치와 행동 발생 횟수(Count)의 상관 계수는 -0.054 이며 매우 약한 음의 관계를 나타내며, 유의 확률은 0.538로서, 유의수준 0.01보다 크기 때문에, 의미 있는 상관 관계가 없다.

표 5. W와 Count, Duration 상관계수

w	Pearson 상관계수	w	Count	Duration
	유의확률 (양쪽)	1	-.054	.802**
	제공할 및 교차곱	382135,759	.538	.000
	공분산	2962,293	-745,830	26776135
	N	130	-5,782	207566,938
Count	Pearson 상관계수	-.054	1	-.034
	유의확률 (양쪽)	.538	.703	.703
	제공할 및 교차곱	-745,830	490,308	-40310,846
	공분산	-5,782	3,801	-312,487
	N	130	130	130
Duration	Pearson 상관계수	.802**	-.034	1
	유의확률 (양쪽)	.000	.703	.000
	제공할 및 교차곱	26776135	-40310,846	2,92E+009
	공분산	207566,938	-312,487	22600003
	N	130	130	130

\*\* 상관계수는 0.01 수준(양쪽)에서 유의합니다.

그림 4의 산점도 에서, 행동 발생 횟수 와 행동 지속 시간의 표본들이 겹치는 부분을 확인 할 수 있다. 즉, 가중치와 행동 발생 횟수의 상관 관계는 행동 지속 시간에 영향을 받을 수 있다. 이 경우, 행동 지속 시간과 겹치는 부분을 제외하고 가중치와 행동 발생 횟수만의 상관관계를 알아보는 편상관관계를 분석한다. 행동 지속 시간을 통제 했을 때, 분석 결과는 표 6과 같이 유의수준이 0.605으로, 0.01보다 크며, 가중치와 행동 발생 횟수의 상관계수는 -0.046으로 의미 있는 상관관계가 없다.

표 6. 가중치와 행동 발생 횟수의 편상관계수

통제변수	w	Count
Duration	상관	-0.046
	유의수준(양쪽)	.605
	df	127
Count	상관	1.000
	유의수준(양쪽)	.605
	df	0

w와 Duration 사이 상관분석 결과, 거주자의 방과 행동에 대한 흥미는 행동 반복 횟수 보다 행동 지속 시간과 더 밀접한 관계를 가진다는 분석을 바탕으로, 비정상 행동 패턴을 분석하는데 행동 지속 시간을 이용한다. 그림 5는 ABA 알고리즘에서 행동 시간에

대한 평균값을 구하는 과정을 나타내며, Step0과 1은 가중치가 0 보다 작거나 같을 경우 Sub action의 평균시간을 구하는 것을 나타내고, Step2와 3은 가중치가 1보다 큰 경우, 즉 이산 가중치 데이터 결과가 나왔을 때의 Sub action의 평균 시간을 구하는 것이다.

```

Step0. If  $w_i(SAct_i, Rm_j) \leq 0$ 
Step1. Then  $AvgSAct_i = AverageDurn(SAct_i)$ 
Step2. If  $w_i(SAct_i, Rm_j) > 1$ 
Step3. Then  $AvgSAct_j = AverageDurn(SAct_i)$ 
    
```

그림 4. 가중치별 Sub action 평균 계산 방법

그림 5는 ABA(Abnormal Behavior Analysis) 알고리즘을 설명한 것이며 보다 상세한 설명은 다음과 같다.

```

Step0. IF ( $durn(MAct_i) < durn(SAct_i)$ )
    Then  $SAct_i \in$  Exception Behavior Category
Step1. For (Exception Behavior Category( $SAct_i$ ))
    if( $location(SAct_i) \cap location(SAct_j) \neq NULL$  or
     $location(SAct_i) \cap location(MAct_j) \neq NULL$  and
     $AvgSAct_i < durn(SAct_i) < AvgSAct_j$ )
    Then  $SAct_i =$  Normal Behavior Category
Step2. if( $location(SAct_i) \cap location(SAct_j) \neq NULL$  or
     $location(SAct_i) \cap location(MAct_j) \neq NULL$  and
     $durn(SAct_i) > AvgSAct_j$ )
    Then  $SAct_i =$  Abnormal Behavior Category
Step3. if( $location(SAct_i) \cap location(SAct_j) = NULL$  or
     $location(SAct_i) \cap location(MAct_j) = NULL$  and
     $durn(SAct_i) > AvgSAct_j$ )
    Then  $SAct_i =$  Abnormal Behavior Categor
    
```

$MAct$  : Main action,  $SAct$  : Sub action

그림 5. ABA(Abnormal Behavior Analysis) 알고리즘

**제 1단계 :**  $MAct$  지속된 시간보다  $SAct$  의 지속된 시간이 많이 경과 했을 경우 이상 행동 범주(Exception Behavior Category)로 분류한다. 그 이유는  $MAct_i$  행동이 종료된 이후에  $SAct_i$  행동이 지속된 경우  $MAct_j, SAct_j$  행동에 연관성이 있거나 혹은 관련이 없을 수 있으므로,  $SAct_i$  지속 시간이  $MAct_i$  의 지속 시간보다 큰 경우를 검색한다. 그리고 위와 같은 상황에서  $SAct_i$  의 가중치는 1보다 큰 값을 가지며 이산 가중치 데이터로 정의한다.

**제 2단계 :** 예외 행동 으로 분류된  $SAct_i$ 이  $MAct_j$  혹은  $SAct_j$  의 발생 시간대의 위치가 겹치며,  $SAct_i$  의 행동 지속 시간이 음수가 아닌 0보다 작은 가중치를 가진  $SAct_i$ 의 평균 시간( $AvgSAct_i$ ) 보다 크고, 이산 가중치를 나타내는  $SAct_i$ 의 평균 시간 ( $AvgSAct_j$ ) 보다 작은

경우를 정상 행동(Normal behavior)으로 분류를 한다.

**제 3단계 :** 3단계와 같이, 예외 행동으로 분류된  $SAct_i$ 의 발생 시간대 위치가  $MAct_j, SAct_j$  의 위치와 겹치지만,  $SAct_i$ 의 행동 지속 시간이, 이산 가중치를 가지는  $SAct_i$ 의 평균 시간 ( $AvgSAct_j$ ) 보다 큰 경우를 비정상 행동(Normal behavior)으로 분류를 한다.

**제 4단계 :** 제 3단계와 반대로, 예외 행동으로 분류된  $SAct_i$ 의 발생 시간대 위치가  $MAct_j, SAct_j$  의 위치와 겹치지 않고,  $SAct_i$ 의 행동 지속 시간이, 이산 가중치를 가지는  $SAct_i$ 의 평균 시간 ( $AvgSAct_j$ ) 보다 큰 경우를 비정상 행동(Normal behavior)으로 분류를 한다.

#### 4. 실험 및 결과 분석

본 논문에서 제시한 ABA 알고리즘의 효과를 알아보기 위해 ABA 알고리즘을 “MIT Placelab” 에서 측정된 행동 데이터에 적용하여 정상/비정상적인 행동을 분류한 경우와, ABA 알고리즘을 사용하지 않고 가중치의 크기 만으로 사용자의 흥미 정도를 파악하는 경우를 비교하는 실험을 수행 하였다. 실험 수행 시 본 논문에서 제안한 가중치 수식에서, 행동 횟수와 행동 지속 시간의 상대적인 중요도 변수 a를 고려하지 않고 가중치를 구한다.

표 7. ABA 알고리즘과 예외 행동 분류를 적용하지 않은 방식을 사용한 행동 분석 결과

Activity	Code	Start Time	End Time	Main action Duration(sec)	Sub action Duration(sec)	w	Behavior Category	
Toileting-Toilet Flush	100	6:44:06 AM	7:12:41 AM	231	1715	7.549	Normal Behavior	Interesting behavior
Toileting-Light switch	101	6:44:20 AM	7:46:34 AM	231	3734	16.289	Normal Behavior	Interesting behavior
Dressing-Medicine cabinet	57	7:34:05 AM	7:42:38 AM	174	513	3.091	Normal Behavior	Interesting behavior
Dressing-Toilet Flush	100	7:34:47 AM	12:26:27 PM	174	17500	100.717	Abnormal Behavior	Interesting behavior
Preparing breakfast-Microwave	143	6:54:09 AM	1:07:43 PM	143	22414	48.143	Abnormal Behavior	Interesting behavior
Grooming-Medicine cabinet	57	7:43:52 AM	12:26:50 PM	125	16974	136.125	Abnormal Behavior	Interesting behavior
Preparing lunch-Freezer	137	11:36:15 AM	4:35:46 PM	2021	16762	8.486	Abnormal Behavior	Interesting behavior
Preparing lunch-Cabinet	55	11:38:48 AM	11:55:42 AM	2021	3131	1.587137	Normal Behavior	Interesting behavior
Preparing a beverage-Light switch	92	4:28:23 PM	6:44:14 PM	1298	8151	6.419	Abnormal Behavior	Interesting behavior
Toileting-Toilet Flush	100	5:43:13 PM	6:41:03 PM	1192	3470	3.411	Abnormal Behavior	Interesting behavior
Dressing-Freezer	137	7:44:44 PM	7:49:33 PM	227	289	1.4398	Normal Behavior	Interesting behavior
Putting away groceries-Light switch	104	7:36:32 PM	7:50:07 PM	815	349	2.478	Normal Behavior	Interesting behavior
Putting away groceries-Light switch	92	7:36:44 PM	7:47:29 PM	349	645	1.9910	Normal Behavior	Interesting behavior

표 7은 ABA 알고리즘 효과 실험 결과로 3월 27일 행동패턴 표본 126개를 이용 하였으며, 가중치가 1보다 큰 행동을 예외 행동으로 분류 하여 정상/비정상 행동을 판단한 결과이다. 그림 6은 행동 패턴 데이터를 시간별로 분석한 Plot 으로서,  $SAct$  의 시간 별 행동이 겹치는 부분을 확인 할 수 있다. 표 7에서, ABA 알고리즘을 적용한 결과 냉동고(Freezer) 문을 약 4시간 반(16761sec) 열어놓은 행동은 비정상 행동으로 분류



되었지만, 예외 행동을 고려하지 않고, 가중치만 고려한 행동 분석 결과는 단순히 흥미 있는 행동으로 분류되었음을 보인다. 즉, 가중치가 다른 행동보다 높게 측정 되었지만 비정상 행동으로 분류가 될 수 있다.

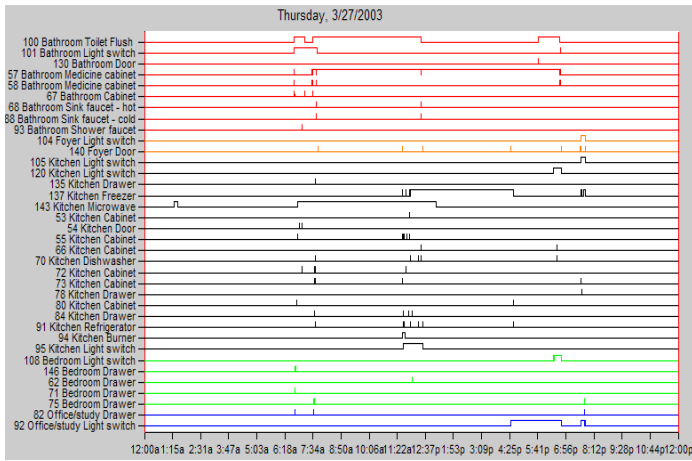


그림 6. 시간별 사용자의 행동패턴 Plot

5. 결론 및 향후 연구 방향

이전 연구에서 개발한 BPP 알고리즘은 예외행동을 고려하지 않고, 가중치가 높을수록 방과 행동에 대한 연관성과 관심이 높다고 정의 했다. 그러나 본 연구에서는 사용자 프로파일의 중요 속성으로 행동 발생 횟수와 행동 지속 시간을 이용하여 가중치를 계산하는 수식을 제안한다. 그리고 가중치와 행동 지속 시간 사이의 밀접한 연관성을 조사 했으며, 조사 결과에 근거하여 ABA(Abnormal Behavior Analysis) 알고리즘을 제안한다. ABA 알고리즘 효과를 분석한 실험 결과, 가중치는 행동 지속 시간과 밀접하게 관련 있으며, 가중치가 높은 행동은 비정상적인 행동으로 분류 될 수 있다. ABA 알고리즘의 효과로는, 이산 가중치 데이터를 나타내는 행동을 예외 행동으로 분류 하여 정상/비정상적인 행동 여부를 객관적으로 판단하는 알고리즘을 제안함으로써, 독거 노인이나, 장애를 가진 환자의 비정상적 행동을 탐지하는 현실적인 헬스케어 홈 서비스 구축을 기대한다. 향후 연구 방향으로서는 사용자의 행동 시간과 동선을 추가하여 사용자 프로파일 데이터를 구축하고, 다음 행동을 예측하는 알고리즘을 개발한다.

참고문헌

[1] 김정기, 박승민, 장재우, “상황인식 처리 기술”, 정보처리학회논문지, 10 권, 4 호, pp.182-188, 2003.  
 [2] Mark Weiser, Ubiquitous Computing, <http://www.ubiq.com/hypertext/weiser/UbiHome.html>  
 [3] H. Si and Y. Kawahara and H. Morikawa and

T.Aoyama, "A Stochastic Approach for Creating Dynamic Context-aware Services in SmartHome Environment", In Proceeding of the 3<sup>rd</sup> International Conference on Pervasive Computing (Pervasive 2005), (Demo paper),Advances in Pervasive Computing, pp. 97-100, Munich, Germany  
 [4] Y.Oh and H.Yoon and W.Woo, "Simulating Context-Aware Systems based on Personal Devices," The 4th International Symposium on Ubiquitous VR(ISUVR2006), pp. 000, 2006.  
 [5] 허혁, 국윤규, 엄영현, 정계동, 최영근, “홈 네트워크 환경에서 홈 서버 그룹 관리를 위한 에이전트 시스템”, 한국정보과학회 2005 한국컴퓨터종합학술대회 논문집(A), 2005. 7, pp. 373 ~ 375.  
 [6] Munguia Tapia, Stephen S. Intille, and Kent Larson, “Activity Recognition in the Home Using Simple and Ubiquitous Sensors,” The Second International Conference on Pervasive Computing, pp. 158-175, 2004.  
 [7] Heeseo Chae, Taek Lee, Hoh Peter In, “Situation Aware RFID system: Evaluating abnormal behavior detecting approach”, 3rd Workshop on Software Technologies for Future Embedded & Ubiquitous  
 [8] D. Jeong, Y.-G. Kim, and H. P. In, "New RFIDSsystem Architectures Supporting SituationAwareness under Ubiquitous Environments,"Science Publications, Journal of ComputerScience, Vol. 1, No. 2 (2005) 114-120  
 [9] Didier Aubert, "Passengers Queue Length Measurement", Image Analysis and Processing, 1999. International Conference on. 1999, 1132-1135