

## An Inference System Using BIG5 Personality Traits for Filtering Preferred Resource

Jong-Hyun Park\*

\*Professor, SW Education Center, Hanshin University, Osan, Korea

### [Abstract]

In the IoT environment, various objects mutually interactive, and various services can be composed based on this environment. In the previous study, we have developed a resource collaboration system to provide services by substituting limited resources in the user's personal device using resource collaboration. However, in the preceding system, when the number of resources and situations increases, the inference time increases exponentially. To solve this problem, this study proposes a method of classifying users and resources by applying the BIG5 user type classification model. In this paper, we propose a method to reduce the inference time by filtering the user's preferred resources through BIG5 type-based preprocessing and using the filtered resources as an input to the recommendation system. We implement the proposed method as a prototype system and show the validation of our approach through performance and user satisfaction evaluation.

▶ **Key words:** BIG five, Resource inference, User personality, Recommender system, Collaboration system

### [요 약]

IoT 환경은 다양한 사물들이 상호 유기적으로 동작하며 이를 바탕으로 여러 서비스를 구성할 수 있다. 앞선 연구에서 우리는 자원 협업을 이용해 사용자의 개인용 단말에 부족한 자원들을 대체하여 서비스하기 위한 자원 협업 시스템을 개발했다. 그러나 앞선 시스템은 자원과 상황의 수가 증가하면 자원 추론 시간이 기하급수적으로 증가한다. 이러한 문제를 해결하기 위하여 본 연구는 BIG5 사용자 유형 분류 방법을 적용하여 사용자와 자원을 분류한다. 또한, 본 논문은 BIG5 유형 기반의 전처리를 통해 사용자가 선호하는 자원들을 필터링하고, 필터된 자원들을 추천 시스템의 입력으로 사용하여 추론 시간을 줄이는 방법을 제안한다. 논문은 제안한 방법을 프로토타입 시스템으로 구현하고 성능 평가와 사용자들의 만족도 평가를 통해 제안한 방법의 유효성을 보인다.

▶ **주제어:** 빅파이브, 자원 추론, 사용자 유형, 추천 시스템, 협업 시스템

- 
- First Author: Jong-Hyun Park, Corresponding Author: Jong-Hyun Park
  - Jong-Hyun Park (jh7park@hs.ac.kr), SW Education Center, Hanshin University
  - Received: 2022. 11. 01, Revised: 2022. 12. 14, Accepted: 2022. 12. 14.

## I. Introduction

IoT 환경의 주 목적 중 하나는 다양한 사물들의 협업을 통하여 최적의 서비스를 구성하여 사용자에게 제공하는 것이다. 이러한 환경에서 사용자는 자신이 보유한 소형의 IoT 단말만으로 다양한 서비스를 제공 받기를 원한다[1, 2]. 예를 들면 그림 1과 같이 사용자는 사물들의 협업이 가능한 공간에서 자신이 보유한 스마트 워치에 발표 서비스를 요청하고 사용하기를 원한다. 그러나 개인용 모바일 기기들이 성능 좋은 입출력 장치나 주변 장치들과 같은 다양한 컴퓨팅 자원들을 다수 포함하게 되면, 그 크기가 소형화되기 어렵다는 것은 피할 수 없는 현실이다. 그러므로 본 논문의 선행 연구는 이러한 환경에서 사용자의 요구사항을 해결하기 위한 자원 협업 시스템을 제안한 바 있다 [3, 4]. 자원 협업 시스템은 자원의 공유가 가능한 환경에서 사용자의 개인용 단말로부터 주변에 공유 가능한 자원들을 검색하고, 이들과의 협업을 통하여 사용자가 원하는 서비스를 사용할 수 있도록 시스템을 구성하여, 사용자에게 제공한다. 이때 중요한 것이 다양한 자원들 가운데 어떤 자원이 사용자가 요청한 서비스에 최적화된 자원인지를 판단하는 것이다.



Fig. 1. Resource Collaboration Service

예를 들어 사용자가 처음 접한 공간에서 스마트워치와 같은 자신의 스마트 단말에 “발표 서비스”를 요청하면 사용자의 스마트 단말은 주변에서 공유 가능한 다양한 자원들 가운데 발표 서비스를 제공하기 위해 필요한 자원들을 검색하고 그들 가운데 최적의 자원을 추천하여 사용자에게 추천한다. 이렇게 추천된 자원들은 최종적으로 사용자에게 의해서 선택되고 연결되어 사용자는 발표 작업을 수행할 수 있다. 자원 협업 서비스를 위하여 이러한 접근 방법이 자연스러운 해결 방법들 가운데 하나일 수 있지만, 실제 응용에 이러한 방법을 사용하기 위해서는 자원 추천을 위해 방대하고 다양한 정보들을 기반으로 정해진 시간에

효과적으로 최적의 자원을 추천하는 방법이 필요하다. 본 논문의 앞선 연구[3]에서 우리는 사용자의 모바일 단말에 자원 협업을 수행하는 프로토타입 시스템을 구현하고 평가한 바 있다. 그러나 그 결과 자원의 수가 많아지고, 반영해야 할 정보의 수가 증가하면 추론 시간은 기하급수적으로 증가했다. 또한, 본 논문에서 대상으로 하는 자원 협업 시스템은 소형의 모바일 단말에서 추론을 수행하므로 제한된 컴퓨팅 자원을 이용한다. 그러므로 사용자가 허락하는 시간을 만족시키면서 최적의 자원을 추천하는 것은 반드시 해결해야 할 문제이다. 이와 함께 자원 추천 결과에 대한 사용자의 만족도 역시 향상되거나 유지되어야 한다.

본 논문은 이러한 요구사항을 해결하기 위하여 존재하는 모든 자원들에 추론 알고리즘을 적용하는 것이 아니라, 전처리 작업을 통해 사용자가 선택할만한 자원들을 먼저 분류한 후, 해당 자원들만을 대상으로 자원을 추천하는 방법을 제안한다. 이러한 전처리 작업을 위해 사용하는 방법은 심리학 분야에서 사용자의 성향을 분류하기 위해 이미 많이 사용되는 BIG5 분류 방법을 기반으로 하는 사용자 유형 기반 자원 분류 방법이다. 논문은 제안한 방법을 앞선 연구에서 개발한 사용자 모바일 단말에 프로토타입 시스템으로 구현하여 사용자의 만족도와 그 성능을 평가한다.

논문의 나머지 구성은 다음과 같다. 2장에는 본 논문의 앞선 연구인 자원 협업 시스템과 관련된 연구들을 기술하며, 3장은 논문에서 제안하는 BIG5를 이용한 자원 추천 방법에 대해 기술한다. 4장은 제안한 방법의 성능을 평가하고 있으며, 마지막으로 5장에서 결론 및 논문의 기대효과에 대해서 기술한다.

## II. Preliminaries

### 1. Resource Collaboration System

그림 2는 자원 협업 시스템의 상세 구조를 보인다. Service Broker가 Resource Reasoner의 Context Request에 서비스를 요청하면, Controller를 통해 해당 서비스를 구성하기 위해서 필요한 모든 정보를 CIB(Context Information Base)를 통해 획득한다. Controller는 협업 시스템 내부에서 데이터와 이벤트의 흐름을 제어하는 역할을 하며, CIB는 온톨로지를 기반으로 자원, 환경 상황 정보 그리고 사용자의 정보를 저장하고 관리하는 역할을 한다. User Context Manager는 사용자의 자원 사용 이력을 기반으로 사용자의 유형을 분류하고 사용자 선호 정보와 프로파일 정보들을 추출하여 최종적

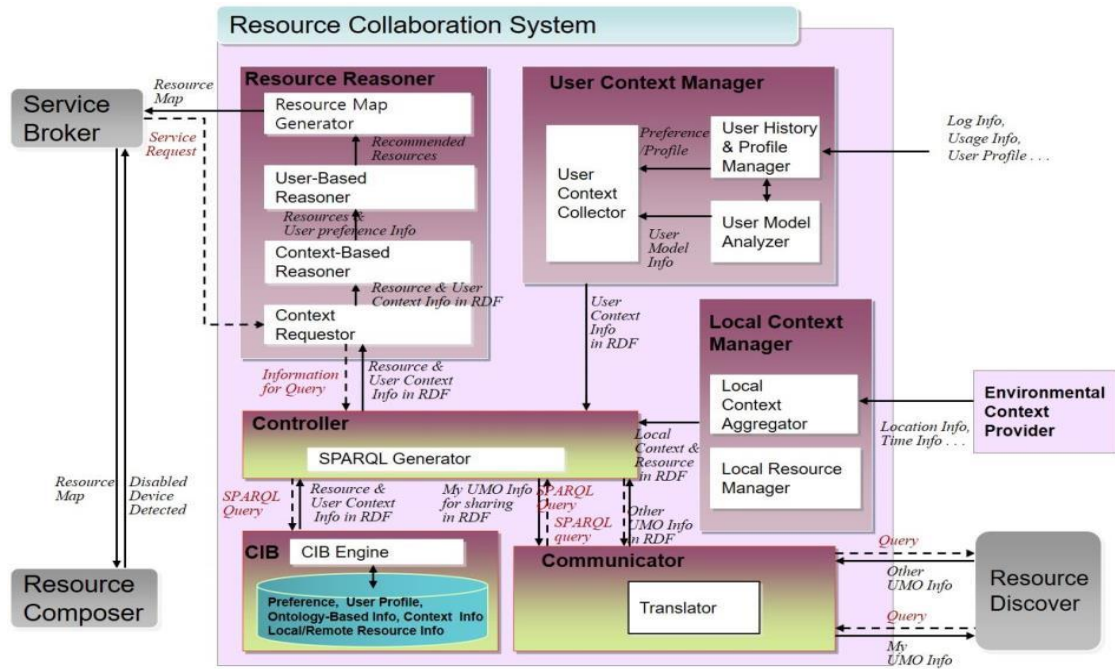


Fig. 2. An architecture of Resource Collaboration System

으로 CIB에 저장한다. Local Context Manager는 다양한 환경 정보들을 수집하고 자신이 보유한 자원들을 관리하며 이를 CIB에 저장한다. Communicator는 다른 자원들과 통신하기 위하여 사용된다. Resource Reasoner는 CIB로부터 자원들의 정보, 환경 상황 정보 그리고 사용자의 정보를 기반으로 자원을 추론하고 추천한다.

## 2. Related Works

본 논문에서 제안한 협업 시스템은 추천의 대상이 자원이라는 특성을 갖지만 큰 범주에서는 개인화 추천 시스템의 한 응용이다. 개인화 추천을 위한 방법은 크게 협업 필터링, 콘텐츠기반 추천방식 그리고 이 두 가지가 결합된 하이브리드 방식으로 구분한다.[5, 6] 협업 필터링 방법은 개별 콘텐츠에 사용자가 점수를 부여하여 모든 사용자의 선호도를 분석하고 이를 이용하여 유사 사용자 집단을 구성한 추천에 활용한다. 이러한 방법은 새로운 사용자나 자원에 대한 적응이 수월하다는 장점이 존재한다.[7, 8] 그러나 본 논문에서 제안하는 자원 협업 시스템은 사용자의 개인용 모바일 단말에서 추론을 수행하므로 다른 사용자의 정보를 획득할 수 없으므로 이를 추천에 활용하는 것은 불가능하다.

콘텐츠 기반 추천 방식은 콘텐츠에 대한 사용자의 선호 이력을 기반으로 이미 평가되어있는 콘텐츠를 활용하여 추천하는 방법이다.[9, 10] 이 방법은 동일 또는 유사한 환경에서 효과적인 결론을 도출해낼 수 있지만 새로운 환경이나 자원에 대해서는 좋은 결과를 기대하기는 힘들다. 특별히 본 논문에서는 새로운 자원들이 다수 추가된 경우 효과

적으로 이를 처리하는 것이 목표이므로 콘텐츠 기반 방법만을 자원 추천을 위해 활용하기는 어렵다. 이러한 문제점을 해결하기 위하여 본 논문에서 역시 하이브리드 방법을 선택했으며 특별히 사용자의 소형 모바일 단말에서 추론을 수행한다는 특성을 고려하여 사용자의 개인정보와 사용 이력을 기반으로 자원 추론을 전처리하는 방법을 제안한다.

앞선 세 가지 접근 방법 이외에도 기존에 추론이나 추천 시스템의 관련 연구는 많이 존재한다. 그러나 BIG5 사용자 유형 분류 방법을 추천 알고리즘에 직접 적용한 연구는 아직 국내·외에서 찾아보기 어렵다. 게임이나 여행 분야에서는 최근 연구가 시작되고 있지만 본 연구와 같이 IoT 환경에서 자원 협업 시스템을 위해서 적용한 경우는 더욱더 찾아보기 어렵다.

## III. Resource Recommendation based on BIG5

### 1. Resource Selection Patterns and BIG5 Personality

사용자 분류 방법을 자원 추론에 적용하기 위하여 가장 중요한 고려사항은 검증된 방법을 사용해야 한다는 것이다. 만약 잘못된 분류 기준이나 방법을 사용한다면 전처리의 결과가 유효하지 못할 뿐만 아니라 추천의 결과에도 영향을 미칠 수 있기 때문이다. 그러므로 본 연구진은 심리

학 분야에서 사용자 유형을 분류하기 위한 방법으로 이미 널리 활용되고 있는 BIG5 분류 방법을 사용하여 전처리 작업을 수행한다[11, 12, 13].

$$C = \{N(r), S(r), P(r), P(r), N(r)\} \quad (1)$$

$$N(r) \mid S(r) \mid P(r) = \frac{No. \text{ Seleted Resource}(r)}{No. \text{ Total Resource}(r)} \quad (2)$$

$$T(r) = \frac{Total \text{ Selection Time}(r)}{No. \text{ Selected Resource}(r)} \times 0.02 \quad (3)$$

$$D(r) = \left(5.5 - \frac{TD(r)}{TN(r)}\right) \times 0.2 \quad (4)$$

심리학 분야에서 가장 영향력 있는 성격 이론 중 하나인 BIG5 성격 이론은 친화성(A-Agreeableness), 성실성(C-Conscientiousness), 외향성(E-Extraversion), 신경증(N-Neuroticism), 개방성(O-Openness)의 5가지 기본 특성을 포함한다. 본 논문은 식(1)과 같이 사용자들의 자원(r) 선택 특성을 수치화 하기위하여 신규 자원 선택 비율(N), 특정 자원 선택 비율(S), 인기 자원 선택 비율(P), 자원 선택 시간(T) 그리고 , 근접 자원 선택 비율(D)을 이용한다.




Fig. 3. Propensity of User Resource Selection by BIG5 Model

예를 들어 사용자가 키보드(k-keyboard)를 선택한 10 회 중 서비스와 관계없이 특정 키보드(k)를 동일하게 선택한 횟수가 4회라면 S(k)는 0.4다. 신규 자원 여부는 처음 추천에 사용된 자원이거나 출시일이 6개월 미만인 자원으로 정의했다. 인기 자원 여부는 특정 자원의 선택율이 평균 선택율의 2배가 넘는 경우 인기자원으로 정의했다. 식(3)은 사용자가 자원을 선택하기위해 사용한 평균 시간이고 식(4)는 사용자가 선택한 자원이 사용자와 떨어진 거리를 수치로 나타낸다. 각 식에 0.02와 0.2를 곱해 다른 특

성값과 비율을 조정한다. 이러한 상수값은 모두 응용의 특성에 맞게 조절할 수 있다.

그림3은 BIG5 사용자 유형에 따른 자원선택의 특성을 보인다. 예를 들어 친화성 값이 평균보다 높은 사용자는 인기자원을 선택하는 비율이 높은 반면 자원을 선택하는 시간이나 특정 자원을 지속적으로 선택하는 비율은 높지 않다. 본 논문은 20명의 남녀 대학생들을 대상으로 실험을 진행했다. 실험에 참여한 대상자들은 [14]를 통해 미리 BIG5 검사를 수행하여 각 특성의 값을 확보하였다. 실험은 프로그래밍을 위한 작업을 위해 각각 키보드, 마우스, 그리고 모니터 자원을 대상으로 하였으며 1주일에 3회씩 3주 동안 총 9회 실시하였다. 매회 실험에서 3개의 신규 자원을 추가하거나 교체하였다.

이러한 실험 결과로 우리는 사용자가 자원을 선택하는 특성을 기반으로 사용자의 BIG5 유형을 추정할 수 있다. 물론 위 5가지 특성만으로 정확하게 BIG5 유형을 예측하는 것은 무리가 있지만, 본 논문의 주된 목적은 사용자의 정확한 BIG5 유형을 추정하는 것이 아니라 사용자의 자원 선택 패턴으로부터 사용자가 선택할만한 자원을 추천할 수 있도록 돕는 것이다. 이를 위해 정확한 기준이 될 수 있는 BIG5 분류 방법을 선택하여 활용한다. [11, 15]와 같은 연구들은 사용자의 다양한 행동 패턴으로부터 BIG5 유형 값을 추정한다. 만약 좀 더 정확한 사용자의 BIG5 유형 분류가 필요하다면 연구들을 참조하면 된다.

## 2. Customized Resource Inference based on BIG five Personality

BIG5 사용자 유형을 고려하여 사용자에게 자원을 추천하기 위해서는 BIG5의 각 성격 유형에 맞는 자원들을 분류해야한다. 이를 위하여 우리는 온톨로지로 미리 정의해 둔 각 자원들의 속성들 중 표 1과 같이 각 유형별 대표 속성(대체 속성 포함)을 정의한다. 예를 들어 자원의 인기도(또는 사용된 전체 횟수) 속성의 경우 인기자원 선택 특성을 대표하는 속성으로 A와 O 유형의 대표 속성에 속한다.

Table 1. Core property of resource based on resource selection characteristic

Propensity (personality)	Properties
Selecion Time (C, N)	SelectionTime
Specific Resource Selection (C, N)	Model (Brand)
New Resource Selection (O, E)	RelData (RegData)
Popular Resource Selection (A, O)	Popularity (UsedTime)
Nearby Resource Selection (O, E)	Distance

사용자의 BIG5 유형을 자원 추천에 반영하기 위해서 본 논문은 자원의 속성값을 정규화하고 해당 값에 사용자의 BIG5 각 성향의 값을 가중치로 곱하여 자원의 선택치를 추정한다. 식(5)는 '거리', '사용시간' 과 같은 연속적인 값을 갖는 속성의 값(x)을 정규화하기 위해서 사용한다.

$$x = \frac{x - \min}{\max - \min}, \text{ 소수 둘째 자리에서 반올림} \quad (5)$$

자원의 속성들은 다양한 값으로 표현된다. 예를 들어, 모니터 자원의 '크기' 속성인 경우 그 값의 종류가 한정된 반면 '출시일' 속성의 경우 매우 다양하다. 그러므로 본 논문은 이를 사용자가 선택한 자원 r의 속성 a의 선택치 ( $\sigma(x/a)$ )를 계산할 때 속성값의 다형성을 반영하기 위하여 식(6)을 이용한다.

식(6)의  $\text{var}(\#ra)$ 는 자원(r)의 속성(a)가 가지는 값들의 가짓수로 사용자의 사용이력으로부터 얻을 수 있다.  $\#a(x)$ 는 사용자의 트랜잭션 데이터 중 자원 속성 a의 값이 x인 수를 나타낸다. 예를 들어 사용자가 20번의 마우스 자원을 선택할 때 마우스의 '버튼' 속성의 총 가짓수는 7가지이고 그 중 속성의 값이 3인 자원을 4번 선택하였다면  $4 \times 7 / 20 = 1.4$ 이다. 표 1의 5가지 대표 속성들을 위한 선택치는 식(7)과 같이 식(6)에 의해서 계산된 선택치에 0에서 1사이의 값으로 정규화한 사용자의 BIG5 평균 값을 가중치로 적용하여 계산한다. 예를 들어 식(6)에 의해 계산된 마우스 자원의 '모델' 속성의 선택치가 1.5이고, 사용자의 성실성과 신경증 값이 각각 0.8, 0.6인 경우 평균인 0.7을 곱하여 해당 자원의 속성에 대한 선호도로 추정한다. 값을 가중치로 적용하여 계산한다. 예를 들어 식(6)에 의해 계산된 마우스 자원의 '모델' 속성의 선택치가 1.5이고, 사용자의 성실성과 신경증 값이 각각 0.8, 0.6인 경우 평균인 0.7을 곱하여 해당 자원의 속성에 대한 선호도로 추정한다. 대표 속성 이외의 속성들은 식(7)의 두 번째 식으로 추정한다. 일반 속성 a의 순위를 나타내는  $rka$ 는 선택치의 값이

가장 큰 값을 갖는 속성이 높은 우선순위를 갖는다.

$A = \{a_1, a_2, a_3 \dots a_N\}$ : 자원의 속성 집합  
 $T = \{t_1, t_2, t_3 \dots t_M\}$ : 사용자 트랜잭션 데이터 집합  
 $\#a(x)$ : 속성 a의 값 x와 동일한 값을 갖는 t의 수  
 $\text{var}(\#ra)$ : 자원의 속성 a의 값들의 가짓 수  
 $pa$ : BIG5 대표속성  
 $P = \{O, C, E, A, N\}$ : BIG5 성격 유형  
 $P_v = (O_v | C_v | E_v | A_v | N_v)$ : 각 성격 유형의 값  
 $rk_a$  = 대표속성 이외의 속성 a의 선택치 순위

$$\sigma(x/a) = \frac{\#a(x) \times \text{var}(\#ra)}{N} \quad (6)$$

$$w(a) = \left\{ \begin{array}{l} \text{avg}(P_v), \quad a = pa \\ \frac{I - rk_i + 1}{\sum_{i=1}^{I-N-5} (I - rk_i + 1)}, \quad otherwise \end{array} \right\} \quad (7)$$

$$ps(r) = \sum_{i=1}^N \sigma(x/a_i) \times w(a_i)$$

표 2의 경우, 일반 속성인 'DPI', '버튼', '색상', '센서방식', 의 선택치 가운데 가장 큰 값은 각각 2.4, 1.6, 1.5, 1.2이다. 그러므로, 속성의 순위는 'DPI', '버튼', '색상', '센서방식'의 순위이며 가중치는 0.4, 0.3, 0.2, 0.1이다.

이는 본 논문에서 몇 차례 실험을 거쳐 정의한 값으로 응용이나 유형과 연관된 자원의 속성들 특성에 따라 유연하게 변경하여 사용할 수 있다.

Table 3. Candidate Mouse resources

RID	M1	M2	M3	M4	M5
Model	m40	ss3	p1	p4	ss3
DPI	4000	600	4000	4000	5000
RelData	6/16	1/16	4/15	6/16	4/15
Button	5	5	5	7	7
Color	gray	white	black	black	red
SensorType	optical	optical	bluetrack	laser	optical
Distance	1	1.5	1	1	4
Popularity	7	9	7	8	9
UsedTime	26	30	17	70	43

Table 2. Transaction Data

TID	Model	DPI	RelData	Button	Color	SensorType	Distance	Popularity	UsedTime
Mu1	mx5	4000	6/16(1)	5	gray	optical	1(0.1)	7	26(0.2)
Mu2	ss3	5000	2/16(0.9)	5	red	Gyroscope	1.5(0.3)	7	60(0.8)
Mu3	sa1	4000	1/16(0.9)	7	white	laser	1(0.1)	6	22(0.1)
Mu4	ss3	6000	2/16(0.9)	3	silver	optical	0.5(0)	7	29(0.3)
Mu5	p1	4000	5/15(0.6)	2	black	bluetrack	1(0.1)	9	36(0.4)
Mu6	p1	4000	1/14(0)	3	silver	laser	1.5(0.3)	9	70(1)
Mu7	m50	4000	6/16(1)	7	black	laser	1(0.1)	8	15(0)
Mu8	m40	1600	4/16(1)	7	black	Gyroscope	1(0.1)	5	41(0.5)
Mu9	p4	4000	9/15(0.7)	2	white	optical	0.5(0)	8	33(0.3)
Mu10	ss3	5000	4/15(0.6)	7	red	Gyroscope	4(1)	9	42(0.5)



Table 4. Estimated Preference scores for a user with BIG 5 personality

RID	M1	M2	M3	M4	M5
Model (0.75)	0.525 (0.7)	1.575 (2.1)	1.05 (1.4)	0.525 (0.7)	1.575 (2.1)
DPI (0.4)	0.96 (2.4)	0.16 (0.4)	0.96 (2.4)	0.96 (2.4)	0.32 (0.8)
RelData (0.3)	0.45 (1.5)	0.45 (1.5)	0.3 (1)	0.45 (1.5)	0.3 (1)
Button (0.3)	0.24 (0.8)	0.24 (0.8)	0.24 (0.8)	0.48 (1.6)	0.48 (1.6)
Color (0.2)	0.1 (0.5)	0.2 (1)	0.3 (1.5)	0.3 (1.5)	0.2 (1)
SensorType (0.1)	0.12 (1.2)	0.12 (1.2)	0.12 (1.2)	0.12 (1.2)	0.12 (1.2)
Distance (0.3)	0.6 (2)	0.24 (0.8)	0.6 (2)	0.6 (2)	0.12 (0.4)
Populirity (0.35)	1.525 (1.5)	0.525 (1.5)	0.525 (1.5)	0.35 (1)	0.525 (1.5)
UsedTime (0.75)	0.6 (0.8)	1.2 (1.6)	0.6 (0.8)	0.6 (0.8)	1.2 (1.6)
Total	4.12	4.71	4.695	4.385	<b>4.84</b>

정규화한 BIG5 유형 O, C, E, A, N의 값이 각각 0.4, 0.8, 0.2, 0.3, 0.7이고 표 2와 같은 사용 이력을 갖는 사용자가 자원 추천 서비스를 요청하여 표3과 같은 마우스 자원들이 검색되었을 경우, 표4와 같은 선호도 추정 결과를 얻을 수 있다. 예를 들어 M1 자원의 인기도 속성의 경우 대표 속성이므로 사용자의 A와 O 유형 값의 평균값인 0.35와 식(6)에 의해 추정된 선택치 1.5를 곱하여 0.525의 값을 추정할 수 있다. 이러한 방법으로 모든 자원의 선택치를 계산하면 M5 자원이 4.84로 가장 높은 선호도 값을 갖는다는 것을 추정할 수 있으며 이를 기반으로 다른 자원들의 순위도 결정할 수 있다. 결국 추천 시스템은 필요에 따라 상위 순위의 자원들만을 선택하여 입력으로 사용할 수 있으며, 이는 전체적인 자원의 추천 시간을 줄일 수 있다. BIG5 유형 기반 추천 방법을 사용하지 않는 앞선 시스템은 M4 자원을 가장 선호도가 높은 자원으로 추정한다. 이는 동일한 상황에서도 BIG5 사용자 분류를 적용한 경우 사용하지 않은 방법과 다른 자원을 추천할 수 있으며, 추천 결과가 사용자의 만족도를 높인다는 것을 다음 실험을 통해서 알 수 있다.

#### IV. Evaluation

본 연구는 선행 연구[3, 4]에서 추천 결과에 대한 정확도와 사용자의 만족도를 검증한 바 있다. 그러므로 논문은 제한한 접근 방법을 선행 시스템과 비교하여 두 가지 방법

으로 평가한다. 첫 번째는 자원 추천 시스템이 소형의 모바일 단말에서 수행하므로 자원이나 속성의 수에 따른 추천 시간의 유효성이며, 두 번째는 실제로 사용할 사용자들의 추천 결과에 대한 만족도이다. 이 두 평가 방법은 선행 시스템을 대상으로 비교 평가한다. 추천 시간의 성능을 평가하기 위하여, 우리는 다수의 다양한 자원들을 추가하기 위한 시뮬레이터를 사용한다. 실험을 위한 모바일 단말은 1.2GHz의 CPU와 1.5GB 메모리를 갖는 위치타입 개인용 장치를 사용한다.




Fig. 4. Inference Time

그림 4는 자원 수 증가에 따른 추론 시간을 보인다. 실험에 사용한 데이터는 추천을 위해 자원을 필터링하기 위한 조건의 수를 100개에서 1000개까지 100개씩 증가시키면서 10개의 속성을 갖는 자원을 10개에서 70개까지 20개씩 증가하면서 평가한다. 실험 결과를 통해 볼 수 있는 것처럼 추론 시간은 조건과 자원의 수에 따라 비례하여 증가한다. 그림 5는 선행 시스템(without)과 BIG5 기반 전처리 후 자원을 추론한 방법의 수행 시간을 보인다. 실험을 위한 전처리 비율은 50%이다. 그러나 이 비율은 응용의 특성에 따라 조절할 수 있다.

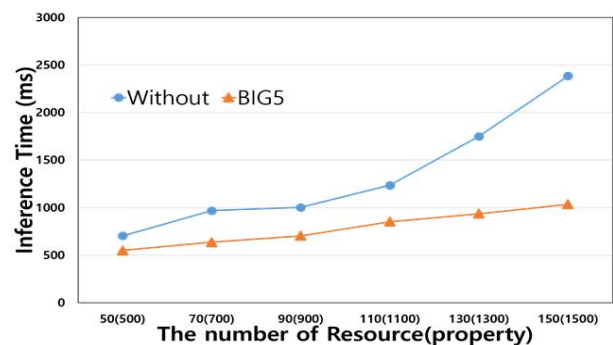


Fig. 5. Comparison of inference times with and without BIG5 type

Table 5. Satisfaction Score

		C, N			O, E, A			합
		D	S	M	D	S	M	
1	B	5	4	2	4	4	4	56
	P	2	4	4	4	4	4	50
2	B	5	4	2	4	4	5	56
	P	2	4	4	4	4	3	48
3	B	5	4	2	4	4	5	61
	P	2	4	4	4	4	3	46
4	B	5	5	2	5	4	5	58
	P	2	4	4	4	4	3	47
5	B	5	5	4	5	4	5	65
	P	2	3	4	4	4	2	48
6	B	5	5	4	5	4	5	63
	P	2	3	4	4	4	2	44
7	B	5	5	4	5	3	5	65
	P	2	3	4	4	3	2	43
8	B	5	5	5	5	3	5	69
	P	2	3	4	4	3	2	44
9	B	5	5	5	5	4	5	68
	P	2	3	4	4	3	2	46
10	B	5	5	5	5	4	5	68
	R	2	3	4	4	3	3	47
11	B	5	5	5	5	4	5	67
	P	2	3	4	4	3	3	50
12	B	5	5	5	5	4	5	71
	P	2	3	4	4	3	3	49



Fig. 6. Satisfaction Score

표 5와 그림6은 C와 N 유형의 값이 높은 실험자 6명과 O, E, A 유형의 값이 높은 실험자 13명을 대상으로 6주 동안 1주에 2회씩 자원 추천 시스템을 사용하여 실험한 결과를 보인다. 실험자를 두 부류로 나눈 이유는 실험에 앞서 실시한 실험자들의 BIG5 유형 테스트 결과 20명의 실험자 가운데 19명의 실험자가 자연스럽게 두 부류로 분류되었기 때문이다. 실험을 위한 자원의 종류는 디스플레이(D), 사운드(S), 마우스(M) 자원이며, 초기 각각 5개씩의 자원으로 동영상 시청 서비스를 수행한다. 매회 한 개의 자원이 교체되고 2회에 한 번씩 새로운 자원을 추가한다. 각 실험은 BIG5 유형을 고려한 추천(B) 방법과 그렇지 않은 선행 연구의 방법(P)으로 각각 수행한다. 실험자는 자원 추천 만족도를 1점에서 5점까지 부여한다. C와 N 유형의 값이 높은 실험자들의 경우 초기에는 두 추천 결과의 만족도에 차이를 보이다가 후반부로 갈수록 차이가 크게 벌어지지 않았으며 대체로 만족도 점수가 높다. 이는 실험

자가 추천 초기에 선택한 자원들을 꾸준히 재선택해서 사용하였으므로 추천 이력이 증가할수록 BIG5를 적용한 경우와 그렇지 않은 경우 모두 동일한 자원들을 추천했기 때문으로 판단된다. O, E, A 유형의 값이 높은 실험자들의 경우 상대적으로 만족도 변동의 폭이 크지만, 전반적으로 BIG5 유형을 고려한 추천 방법의 결과 만족도가 높다.

## V. Conclusion

IoT 환경의 목적들 가운데 한 가지는 주변에 공유가능한 자원들과의 협업을 통해 사용자가 요구하는 서비스를 막힘 없이 제공하는 것이다. 이를 위하여 본 논문은 앞선 연구에서 자원 협업 시스템을 제안했다. 그러나 효과적인 자원 추천을 위해서는 제한된 자원을 갖는 소형 단말에서 다수의 자원들을 대상으로 다양한 추천 조건들을 반영하여 사용자가 허락할 수 있는 시간 안에 만족할만한 추천 결과를 도출해내는 것이 반드시 선행되어야 한다. 본 논문은 자원 추천을 위한 추론 시간을 줄이기 위해 사용자가 선택할만한 자원들을 미리 필터링하여 추천 시스템의 입력으로 사용한다. 이를 위하여 심리학 분야에서 이미 검증된 BIG5 유형 분류 방법을 자원 추론을 위한 전처리 방법에 적용하였다. 논문은 제안한 방법을 자원 협업을 위해서 개발된 모바일 단말에 프로토타입 시스템으로 구현하여 그 성능을 평가하였다. 또한, 논문은 실험을 통해 제안한 방법의 사용 만족도가 그렇지 않은 방법에 비해 높다는 것을 보였다. 본 논문의 결과는 향후 IoT 환경에서 자원 협업을 위해서는 물론이고 사용자의 유형을 고려하여 추천하기 위한 추천 시스템에 활용될 수 있을 것으로 기대된다. 이와 함께 현재 게임과 같은 분야에서는 이미 심리학 분야의 많은 모델을 추천에 이용하고 있으므로, 자원 협업을 위해서 BIG5 유형을 정보기술 분야에 활용하는 예로 참조할 수 있을 것으로 사료된다. 프로토타입 시스템의 개발과 평가의 문제 때문에 현재 본 연구는 자원의 대상을 통신이 가능한 물리적인 컴퓨팅 자원을 대상으로 연구했다. 그러나 향후 우리는 자원의 대상을 SW 자원까지 확장하여 연구할 계획이다.

## ACKNOWLEDGEMENT

This work was supported by Hanshin University Research Grant.

## REFERENCES

- [1] A. Schmidt, "Ubiquitous Computing: Are We There Yet?," Computer Vol. 43, No. 2, pp. 95-97, Feb. 2010. DOI: 10.1109/MC.2010.54
- [2] J. L. Hernandez-Ramos, M. V. Moreno, J. B. Bernabe, D. G. Carrillo and A. F. Skarmeta, "SAFIR: Secure access framework for IoT-enabled services on smart buildings," Journal of Computer and System Sciences, Vol. 81, No 8, pp. 1452-1463, Dec. 2015. DOI:10.1016/j.jcss.2014.12.021
- [3] J.H. Park, "Customized Resource Collaboration System based on Ontology and User Model in Resource Sharing Environments," Journal of The Korea Society of Computer and Information, Vol. 23, No. 4, pp. 107-114, Apr. 2018. DOI:10.9708/jksci.2018.23.04.107
- [4] J.H. Park, "Personalized Recommendation based on Context-Aware for Resource Sharing in Ubiquitous Environments", Journal of The Korea Society of Computer and Information, Vol. 16, No. 9, pp. 19-26, Sep. 2011. DOI:10.9708/jksci.2011.16.9.019
- [5] C. Rana, S. K. Jain, "A study of the dynamic features of recommender systems" Artificial Intelligence Review, Vol.43, No.1, pp.141-153, Jan. 2012. DOI:10.1007/s10462-012-9359-6
- [6] B. Walek, V. Fojtik, "A hybrid recommender system for recommending relevant movies using an expert system," Expert Systems with Applications, Vol. 158, Nov. 2020. DOI:10.1016/j.eswa.2020.113452.
- [7] H. Liu, X. Kong, X. Bai, W. Wang, T. M. Bekele, F. Xia, "Context-Based Collaborative Filtering for Citation Recommendation," IEEE Access, Vol 3, pp. 1695-1703, Oct. 2015. DOI: 10.1109/ACCESS.2015.2481320
- [8] P. Tian, "Collaborative filtering recommendation algorithm in cloud computing environment. Comput," Computer Science and Information Systems, Vol. 18, No. 2, pp. 517-534, Dec. 2021. DOI:10.2298/CSIS200119008T
- [9] M. Zanker, F. Ricci, D. Jannach, and L. Terveen, "Measuring the impact of personalization and recommendation on user behaviour", International Journal of Human-Computer Studies, Vol.68, No.8, pp. 469-471, Aug. 2010.
- [10] S. Niklander, "Emotions Inference Through Content and Sentimental Analysis in COVID-19 Context," Proceedings of HCII 2022, pp. 589-592, 2022. DOI: 10.1007/978-3-031-06391-6\_73
- [11] S. Bai, B. Hao, A. Li, S. Yuan, R. Gao, T. Zhu, "Predicting Big Five Personality Traits of Microblog Users," Proceedings of Web Intelligence 2013, pp. 501-508, 2013. DOI: 10.1109/WI-IAT.2013.70
- [12] K. Mori, H. Umemura, "An analysis of the relationship between immediate response syndrome and the Big Five Personality Scale using structural equation models," Proceedings of KES 2017, pp. 2014-2021, 2017. DOI:10.1016/j.procs.2017.08.140
- [13] F. Celli, B. Lepri, "Is Big Five Better than MBTI? A Personality Computing Challenge Using Twitter Data," Proceedings of CLIC-it, pp.93-98, 2018. DOI: 10.4236/psych.2022.1310095
- [14] Kakao Big five, <https://together.kakao.com/big-five>
- [15] Y. Wang, M. Zhang, P. Soleimaninejadian, H. Tong, Z. Feng, "Big Five Personality Measurement Based on Lifelog," Proceedings of LTA@MM 2017, pp. 25-28, 2017. DOI:10.1145/3133202.3133207

## Authors



Jong-Hyun Park is received his Ph.D. and M.S. degrees in computer science from Chungnam National University, South Korea, in 2002 and 2007, respectively, and his B.S. degree in computer science from Woosong

University, South Korea, in 1999. Dr. Park is a professor at SW education center in Hanshin University, since 2018. He was a visiting professor at Dept. of computer engineering & science in Chungnam National University, from 2011 to 2018. He has researched at the Research Institute for Information Technology of the Kyushu University, JAPAN, in 2009. His research interests include recommender system, Resource Collaboration, Context-Awareness, M2M, IoT, Reasoning, Personalization, Semantic Web, and Database systems.