



Average Pattern and Trial-error Learning Method in Context-aware Home System

Byounghee Son, Suchul Hwang*

Department of Computer Systems and Engineering, Inha Technical College

ABSTRACT

In this paper, we propose a context-aware system to predict one's location in behavior patterns of users. If a new behavior pattern is entered, the system runs a perceptual learning process. While running, the system uses the past three statuses and the current status information and obtains a relationship with the link. The relationship is an average pattern, which is stored and referred in a database system. The proposed system predicts the top four patterns having a high weight value among the average patterns. We suggest an algorithm by making an average pattern and using the trial-error learning method. The system offers a suitable service by considering user's characteristics and recognizing user's average pattern in context-aware environments. However, this paper uses just the user's location data. Even though the system uses the average patterns and trial-error learning for the various variables of context information, the real-time response will be stable and rapid. The proposed scheme has a tendency for the accuracy of prediction to gradually enhance getting the average patterns to increase and the trial-error learning times to decrease. This algorithm will improve the accuracy and reliability of prediction for the incremental context information by incorporating various context information data and provide optimum services to users by suggesting an intellectual reasoning and prediction method based on hierarchical context information.

© 2016 KKITS All rights reserved

KEYWORDS : Fuzzy theories, ARTMAP, Average pattern, Trial-error learning, Context-aware

ARTICLE INFO: Received 2 June 2016, Revised 13 June 2016, Accepted 13 June 2016.

*Corresponding author is with the Department of
Computer Systems and Engineering, Inha Technical

College, 100 Inha-ro Nam-gu Incheon, 22212, KOREA.
E-mail address: schwang@inhac.ac.kr

1. 서론

유비쿼터스 환경에서는 가상공간을 현실화하기 위하여 현실 상황 중 가상공간에서 몇 가지 상황들을 정보화한 후 이를 기반으로 상황 인식 서비스 기술[1]을 적용한 뒤 사용자 중심의 지능화된 서비스를 제공하고 있다. 앞으로 상황 인지 서비스는 현실 세계의 모든 상황을 표현하는 기술적 수단을 제시하며, 이를 기반으로 상황이나, 상황의 특징 추출, 학습, 추론 등의 고 지능화된 기법을 적용하여 사용자의 현재 상황을 특성화하고 더 나아가 최적의 서비스를 제공하게 될 것이다.

상황에 대한 정의는 다양한 모습으로 제시되었다. 대부분의 사람들이 상황이 무엇인지를 무언적으로 이해하여 이를 구체적으로 정의하는 것이 어려웠으나 최초로 상황 인지의 용어와 정의를 성공적으로 소개한 사례인 Schilit와 Theimer의 경우, 상황은 '위치'를 의미하는 것으로 근접한 사람과 사물의 확인 및 이러한 실체에 대한 변화를 의미한다고 하였다[2][3]. 향후 유비쿼터스 시대의 응용 및 서비스는 컴퓨터 및 커뮤니케이션 능력을 가진 스마트 디바이스의 종류가 매우 다양해 질 것으로 내다보고 있다[4]. 하지만 다양한 종류의 센서 정보에도 불구하고 단순한 센서 및 제어 기술을 사용한 서비스는 한계가 있는 제한된 상황 인지 서비스라 할 수 있다. 따라서 보다 고차원의 서비스를 제공받기 위해서는 단편화된 상황정보가 아닌 유기적인 상황정보와 스스로 적용할 수 있는 상황 인지 시스템을 개발하는 것이 중요하다 [5].

본 논문에서는 위치 상황 정보들 간의 상호 관계를 사용자의 평균 패턴으로 인식하고 사용자의 행동을 예측하는 Average pattern기술과 상황 정보에 시행착오를 거쳐 사용자의 새 행동 패턴을 스스로 학습할 수 있는 Trial and Error Learning기술에 초점을 둔다.

본 논문의 구성은 2장에서 관련기술인 Flexible Window 기법과 ART 모델을 설명한다. 3장에서는 제안된 알고리즘과 예측정확도 향상을 위한 방안들에 대해 설명한다. 4장에서는 제안된 알고리즘과 기존의 기법을 이용한 위치 예측 알고리즘을 비교하여 시뮬레이션을 통해 분석한다. 마지막으로 5장에서는 연구에 대한 결론을 맺는다.

2. 관련 연구

2.1 Flexible Window 기법

Flexible Window 기법은 하나의 상황 정보를 예측 하는데 있어 고정된 윈도우 사이즈가 아닌 하나의 상황 정보를 예측 하는데 있어 윈도우 사이즈를 정확도가 높아지는 순으로 크기를 변화시키는 방법이며, 윈도우 사이즈를 더 이상 원하는 상황 정보와 매치가 되지 않을 때까지 예측을 시도하기에 정확도가 높아지는 순으로 증가시킬 수 있다 [5].

윈도우 사이즈를 증가시킨 후 각 상황 정보를 비교하며 해당 윈도우 사이즈에 원하는 상황 정보가 매치되지 않을 때까지의 상황정보 시퀀스가 최고 빈도이고, 그 다음 상황 정보가 우리가 예측하는 상황 정보가 된다.

2.2 ART 모델

적응 공명 이론 (ART: Adaptive Resonance Theory)는 인간 인식 정보처리의 이론으로 Grossberg에 1976년 소개되었다 [7]. 이 이론을 바탕으로 감독 및 비 감독 카테고리 학습과 패턴인식을 위한 실시간 신경망의 여러 모델들이 개발되었다 [8][9]. ART는 고속 또는 저속 학습을 하면서 임의의 입력패턴에 응답해서 안정된 인식 카테고리

리를 학습하는 능력을 갖는다.

비 감독 ART 모델 중 Fuzzy 이론[10][11][12]을 적용한 Fuzzy ART는 임의의 순서로 제공되는 이진이나 아날로그 입력 패턴에 응답해서 자체적으로 카테고리할 수 있는 학습 능력이 있다 [13].

감독 ART 모델 중 Fuzzy ARTMAP은 예측 오차를 최소화 하면서 예측의 일반성을 최대화하여 최적 크기의 안정된 인식 카테고리를 만들며, 아날로그 또는 이진 입력 벡터를 안정된 카테고리로 빠르게 매핑할 수 있다 [14].

3. Average Pattern - Trial and Error Learning 기법을 이용한 위치 예측 알고리즘

본 장에서는 기존의 예측 알고리즘과는 다른 접근 방식을 통해 상황 정보의 상호 관계를 고려하여 사용자의 습관이나 행동양식을 평균 패턴으로 인식함으로써, 상황인지 시스템의 상황 정보와 최대한 부합시켜 이를 통해 상황예측을 가능하게 하며, 새로운 타입의 패턴 입력 시에는 시행착오를 거쳐 학습하는 기법을 이용하여 상황에 따라 스스로 적응하는 위치 예측 알고리즘을 제안한다.

Flexible Window Matching 알고리즘을 통한 상황인지 환경에서의 상황 정보 예측은 동일한 사이즈의 윈도우를 적용시키지 않고 예측될 상황 정보를 제외한 가장 최근의 상황 정보의 시퀀스의 사이즈를 증가시킨다. 시퀀스의 사이즈를 증가하는 과정은 예측 시도에 대한 정확도가 높아지는 윈도우 사이즈 순으로 시행하게 된다. 이런 Flexible Window 알고리즘은 과거 히스토리의 시퀀스에 없는 새로운 행동 패턴이 입력으로 들어오게 될 경우 해당 시퀀스가 없음에도 불구하고 Match하는지 알기 위하여 정해진 최대 Window 사이즈까지 크기를 증가시키며 히스토리의 모든 시퀀스를 탐색시

키기 때문에 기하급수적으로 증가하는 상황 정보량에 대한 처리 지연 시간 문제가 있다.

제안하는 Average pattern 기법은 Flexible Window 사이즈가 아닌 Window 사이즈를 3으로 고정한다. 3으로 고정시키는 이유는 Flexible Window 기법이 대체로 윈도우 사이즈가 적을수록 정확도가 높지만, 사용자의 행동 패턴에 따라 Window 사이즈가 유동적이다. 따라서 본 논문에서는 Flexible Window 사이즈에 따른 정확도와 사용자의 평균 패턴과의 관계를 고려하여 Window 사이즈를 3으로 고정시킨다.

상황 정보가 입력되면 이전의 상황 정보와 연결시켜 사용자의 다음 행동 패턴을 예측 한다. 예측은 상호 관련된 상황 정보를 트레이닝을 통해 학습된 히스토리 중에서 일치하는 예측 상황 중 가중치가 높은 상위 4번째까지의 평균 패턴을 사용자에게 보여준다.

예를 들면, 'd' 라는 상황 정보가 입력되었을 때 이전에 입력된 상황 정보가 'acbe' 였다면, 다음 상황을 예측하기 위해 'd' 라는 상황 정보는 'cbcd' 로 연결시켜 가중치를 증가시키고, 'bed' 로 시작하는 히스토리를 검색한 뒤 가중치가 가장 높은 상위 4가지 평균 패턴을 예측 하는 것이다.

사용자는 알고리즘에 의해 예측된 4가지 중 자신이 받고 싶은 서비스를 선택해 준다. 선택된 평균 패턴은 가중치를 증가시켜 다음 상황 예측 시에도 올바르게 작동 할 수 있도록 해준다. 만일, 예측된 4가지 중에서 사용자가 받고 싶은 서비스가 없을 시에는 기타 선택으로 사용자가 받고 싶은 서비스를 선택하도록 한다.

사용자가 선택한 상황 정보는 Trial and Error Learning에 의해서 스스로 지각학습과 통찰학습 중 선택 학습을 한다. 해당 패턴이 히스토리에 있지만 가중치가 낮아서 예측에 없던 경우일 때는 지각학

습을 통해 패턴을 학습하고, 히스토리에 없는 새로운 패턴일 경우에는 통찰학습을 통해 새로운 패턴을 히스토리에 저장시킨다. 두 경우 모두 학습을 한 뒤에는 패턴의 가중치를 증가 시켜줘 다음 상황 예측에 올바르게 작동할 수 있도록 해준다. 그 동작과정은 다음 <그림 1>과 같다.

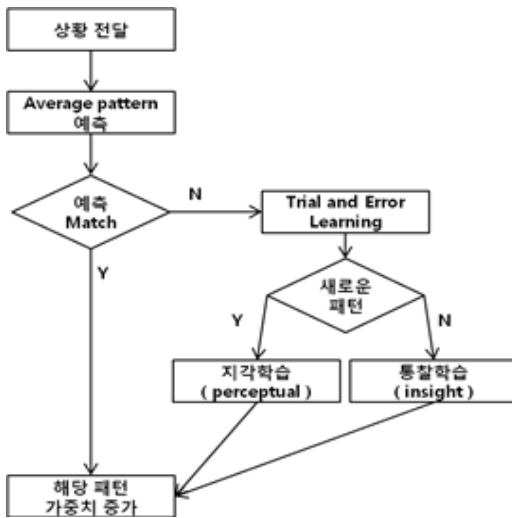


그림 1. Average Pattern - Trial and Error Learning 수행과정
Figure 1. The Process of Average Pattern - Trial and Error Learning

4. 시뮬레이션

4.1 데이터 추출 방법

본 논문에서는 독일의 Augsburg 대학에서 공개한 AILTB[15]를 이용하여 실험 군의 이동 데이터를 데이터베이스에 저장한 후 성능 평가를 수행한다. 데이터의 추출 과정은 다음과 같다. 4명의 다른 사용자가 각각 PDA를 들고 다닌다. 이들이 소지한 PDA에는 그들이 위치한 건물 한 층의 섹터 배치도가 GUI로 표현되어 있고 각 사용자들은 특정 섹터에 들어갔을 때 PDA위의 해당 구역을 클릭한다.

그러면 누가, 언제, 어디에 있는지에 대한 상황정보가 PDA에 저장이 된다. 섹터 정보는 <표 1>과 같으며 엔트리의 수는 <표 2>와 같다.

표 1. 섹터 정보
Table 1. The Information of Sectors

Location	Zone	Description
402	402	Office of person A and B
403	403	Office of person D
404	404	Secretary
405	405	Room P
406	406	Room C
407	407	Room N
408	408	Room D
409	409	Meeting room
410	410	Room A
411	411	Room L
412	412	Office of person C
restroom	1	Restroom
kitchen	2	Kitchen
stairway	3	Stairway
corridor	4	Corridor
printer	5	Printer
elevator	6	Elevator
away	7	The person is away

표 2. 각 사용자 별 엔트리 수
Table 2. The Number of Entries

Person	계절	기간	엔트리 수
A	여름	1 주	101
	가을	4 주	432
B	여름	2 주	448
	가을	5 주	982
C	여름	2 주	351
	가을	4 주	911
D	여름	2 주	158
	가을	7 주	848

4.2 데이터 내부 구조

데이터 추출을 위한 실험은 시뮬레이션의 신뢰

도를 높이기 위해 네 명의 연구원 (A, B, C, D)에 의해 여름과 가을 두 차례에 걸쳐 수행되었다. 즉 피실험자를 다수로 두고 실험 시기 역시 계절별로 다르게 하여 알고리즘 예측 정확도의 신뢰도를 높였다. 각 피실험자의 상황 정보는 사용자 위치 정보의 상호 관계만을 고려한다.

피실험자가 특정 섹터에 들어갈 때마다 상황 정보는 사용자의 위치 정보만이 PDA에 저장된다. 즉, 본 논문에서 상황 정보는 시뮬레이션의 기반이 되는 위치 정보로서 피실험자가 액세스한 섹터만을 고려하여 시뮬레이션을 수행하였다.

본 논문에서는 사용자의 행동패턴을 하나의 단위로 상황 정보를 인식하기 때문에 입력된 여름과 가을의 데이터 엔트리를 행동패턴 단위로 비교하여 동일한 패턴을 사용자의 평균패턴으로 행동 양식을 규정짓고 트레이닝 데이터로 시뮬레이션을 수행한다.

4.3 시뮬레이션 결과

Average pattern 은 각 피실험자들의 여름과 가을 기간에 얻어진 이동 기록 데이터 간의 연관 관계를 발견 하여 그것을 통해 피실험자 특징 별 예측이 가능하도록 한다. 여름과 가을의 데이터를 처음에서 끝까지 행동패턴 단위 4만km 크기로 비교해 나가면서 일치한 부분을 찾아내어 Average pattern 에 대한 트레이닝을 실시한다. 이 트레이닝을 거치면 각 피실험자 별로 Person A는 30개, Person B는 54개, Person C는 57개, Person D는 47개의 평균 패턴이 생성되었다.

Trial and Error Learning은 트레이닝 이후 시뮬레이션 수행을 할 때 학습된 내용으로 Person A는 통찰학습은 12회 지각학습은 0회였고, Person B는 통찰학습 39회 지각학습 1회, Person C의 경우 통찰학습 40회 지각학습 0회, Person D는 통찰학습

42회 지각학습 0회로 나타났다. 대부분 지각학습이 이루어진 경우는 매우 적었다. 이를 통해 가중치가 낮아 예측되지 않는 경우는 적은 것을 알 수 있다.

상황 정보를 사용자의 행동 패턴 단위로 상호 관련시켜 상황 인지 시스템의 의미에 부합하는 방식으로 예측이 높은 정확도가 얻어지는 것을 검증한 후, 알고리즘의 성능을 평가하였다.

표 3. 각 사용자에게 대한 Average Pattern- Trial and Error Learning 방안에 따른 예측 정확도
Table 3. The Accuracy of Average Pattern - Trial and Error Learning about Each Person

Schema	Person Type			
	A	B	C	D
Flexible Window	85.23	83.73	75.39	81.70
Average Pattern - Trial and Error Learning	96.76	95.72	95.39	94.81

시뮬레이션에서 사용된 데이터 흐름도는 <그림 2>와 같으며 미니명세서는 <표 4>와 같다.

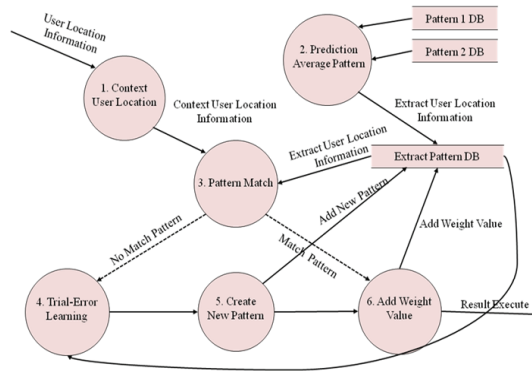


그림 2. 데이터 흐름도
Figure 2. The Data Flow Diagram

<표 3>을 통해 각 사용자에게 대해 Flexible

Window의 정확도와 비교하여 제안하는 알고리즘이 약 14.16% 더 우수한 성능을 얻을 수 있음을 알 수 있다. 그 이유로 사용자의 평균적인 행동패턴이 분석됨으로 사용자에게 맞는 예측을 통해 우수한 성능을 얻을 수 있었으며, 4가지의 패턴을 예측하여 서비스 해주어 정확도가 높아지게 됐다. 이 점은 논문상에서는 18개의 섹터에 의해 다양한 패턴의 생성되었지만, 섹터의 수가 적어질수록 생성되는 패턴의 수는 줄어들기 때문에, 보통 가정애 쓰일 상황인지 시스템에는 더욱 높은 효과를 보이게 된다.

또한, 시행착오 학습을 통해서 점차 시행착오 학습률이 떨어지기 때문에 시스템이 진행될수록 정확도는 높아지게 된다.

표 4. 미니 명세표
Table 4. The Mini-Specification

<p>1. Predict Location = Context User Location + Prediction Average Pattern + Pattern Match + Trial-Error Learning + Create New Pattern + Add Weight Value</p> <p>1.1 Context User Pattern = User Location Information</p> <p>1.2 Prediction Average Pattern = Pattern 1 DB + Pattern 2 DB + Compare Flexible Pattern + Compare Extract Pattern + Create New Pattern + Add Weight Value</p> <p>1.3 Pattern Match = Extract Pattern DB + Compare Extract Pattern & User Location</p> <p>1.4 Trial-Error Learning = No Match Pattern Information + Extract Pattern DB</p> <p>1.5 Create New Patter = No Match Pattern Information</p> <p>1.6 Add Weight Value = Match Pattern Information</p>

3. 결론

본 논문에서는 상황 인지 환경에서의 사용자 위치 예측 시 기존의 Flexible Window를 사용한 위치

예측 알고리즘 보다 예측 정확도 측면에서 더 향상된 성능을 가지는 Average pattern - Trial and Error Learning을 사용한 위치 예측 알고리즘을 제안하였다. Average pattern - Trial and Error Learning 알고리즘은 기존의 Flexible Window 알고리즘과 달리 사용자의 평균 패턴을 인식함으로 예측 시에 사용자의 특성에 따라 예측이 가능하도록 하는 알고리즘이다. 기존의 Flexible Window를 사용한 위치 예측 알고리즘에서는 하나의 상황정보를 예측하기 위해 예측 요청이 올 때마다 Window 사이즈를 증가시키며 매치를 수행한다. 이는 상황인지 시스템과 같은 실시간 응답 시스템에 합리적인 방법이 아니다. 매치하는 상황이 없을 때 Window 사이즈가 최대가 될 때 증가되기 때문이다. 그러므로 상황 정보를 행동 패턴으로 고정시켜 사용자의 Average pattern을 학습하고 Trial and Error Learning을 하는 방법이 합리적이다. Average pattern - Trial and Error Learning을 사용한 위치 예측 알고리즘의 타당성은 Average pattern 학습이 증가할수록, Trial and Error Learning이 줄어들수록 정확도가 증가하는 사실에서 검증되었다. 이를 근거로 제안한 알고리즘에 따라 각 사용자 별 예측 정확도를 평가한 결과, 평균 14.16%의 성능 향상을 얻을 수 있었다. 이 방식은 기하급수적으로 늘어나는 상황 정보를 감안했을 때 알고리즘 수행 시 처리 시간의 감소와 예측 정확도를 향상 시킬 수 있을 것이다.

References

[1] S. W. Ryu, H. S Jang, D. C. Shin, and S. K. Park, *Technology trends of context awareness*, National IT Industry Promotion Agency, Weekly Technology Trends, Vol. 1435, pp. 1-10, 2010.

- [2] B. Schiliti, N. Adams, and R. Want, *Context-aware computing applications*, Proceedings of the 1st International Workshop on Mobile Computing Systems and Applications, pp. 85-90, 1994
- [3] Y. Nishibe, H. Waki, I Morihara, M. Kajihara, and H. Adachi, *Mobile digital assistants for community support*, AAAI Magazine, Vol 19, No. 2, pp. 31-49, 1998.
- [4] R. Want, A. Hopper, V. Falcão, and J. Gibbons, *The active badge location system*, ACM Transactions on Information Systems, pp. 91-102, 1992.
- [5] J. H. Kim, and K. C. Shin, *Trends towards context-aware service technology*, Weekly Technical Report 1178, Institute of Information Technology Assessment, Dec. 2004.
- [6] B. H. Son, Y. H. Kim, and H. B. Kim, *Design of a user location prediction algorithm using the flexible window scheme*, The Journal of the Korean Institute of Communications and Information Sciences, Vol. 32, No. 6 pp. 550-557, 2007.
- [7] G. A. Carpenter, S. Grossberg, and J. H. Reynolds, *ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network*, Neural Networks, Vol. 4, pp. 565-588, 1991.
- [8] U. Ahmed, A. Gavrilov, S. Y. Lee, and Y. K. Lee, *Context-aware fuzzy artmap for received signal strength based location systems*, Proceeding of Neural Networks, pp. 2740-2745, 2007.
- [9] N. O. Seul, *Real-time neural network for information propagation of model objects in remote position*, The Journal of the Korea Contents Association, Vol. 7, No. 6, pp. 45-51, 2007.
- [10] Y. K. Kim, and S. Y. Cho, *Interval valued vague set reasoning based on fuzzy Pr/T nets*, Journal of Knowledge Information Technology and Systems, Vol. 2, No. 4, pp. 53-62, 2007.
- [11] S. Y. Cho, *Reliability analysis of fuzzy systems with weighted components using interval valued vague sets*, Journal of Knowledge Information and Systems, Vol. 3, No. 2, pp. 31-40, 2008.
- [12] S. C. Lee, C. S. Lee, and S. Y. Cho, *Measuring similarity between interval-valued vague sets*, Journal of Knowledge Information and Systems, Vol. 4, No. 2. pp. 15-22, 2009.
- [13] B. Vigdor, and B. Lerner, *The bayesian ARTMAP*, IEEE Transactions on Neural Networks, Vol. 18, No. 6, pp. 1628-1644, 2007.
- [14] A. Kaylani, M. Georgiopoulos, M. Mollaghasemi, G. C. Anagnostopoulos, C. Sentelle, and M. Zhong, *An adaptive multiobjective approach to evolving ART architectures*, IEEE Transactions on Neural Networks, Vol. 21, No. 4, pp. 529-550, 2010.
- [15] J. Petzold, *Augsburg indoor location tracking benchmarks*, Technical Report 2004-09, Institute of Computer Science, University of Augsburg, Germany, 2004.

Average Pattern - Trial and Error Learning 기법을 사용한 행동 패턴 예측 알고리즘 구현

손병희, 황수철

인하공업전문대학 컴퓨터시스템과

요 약

본 논문에서는 상황인지 시스템의 상황정보를 사용자 행동패턴 단위로 인식하여 사용자의 평균패턴과 비교하여 위치를 예측하고 새로운 행동 패턴이 입력 될 경우 자가 학습하는 알고리즘을 제안한다. 과거 상황정보 3가지와 현재 상황정보 1가지를 연결하여 상황정보들 간의 상호 관계의미를 지닌 행동 패턴 단위로 데이터베이스에 저장시켜 사용자의 이전 상황과 현재 상황을 평균 패턴으로 검색하여 검색된 평균 패턴들 중에 가중치가 높은 상위 4가지 패턴을 예측한다. 만일, 예측 되지 않은 경우 사용자의 평균 패턴이 시행착오 학습 작업된다. 제안된 Average pattern - Trial and Error Learning 기법을 이용한 위치 예측 알고리즘은 트레이닝된 상황에서 평균적으로 95.67% 예측이 성공하였다. 이 방식은 행동패턴 단위를 사용하여 사용자의 평균 패턴을 분석하여 예측 정확도를 높이고, 데이터베이스 탐색 시 유동적인 단위보다 탐색 시간이 감소되며, 기존의 없는 행동패턴에 대해서는 탐색 없이 학습이 되어 한정된 시간 내에 사용자가 원하는 서비스 해주어야 할 실시간 시스템에서의 예측시간을 확정해준다.



Su Chul Hwang received the bachelor's, the M.S. and Ph.D. degree in the Department of Computer Science from the Chung-ang University in 1986, 1988 and 1993, respectively. He has been a professor in the Department of Computer Systems and Engineering at Inha Technical College since 1991. His current research interests include artificial intelligence, intelligent systems, Internet Application, IT fusion system etc. He is a life member of the KKITS.

E-mail address: schwang@inhatec.ac.kr



Byounghee Son received the bachelor's degree from Woosuk University, Jeonbuk, Korea, in 1995. After graduating, she worked at Proface Korea Co., Ltd., for six years as an engineer. She received her M.S. and Ph. D. degree in electrical engineering from Yonsei University, Seoul, Korea, in 2003 and 2012, respectively. She is currently giving a lecture at Inha Technical Collage, Incheon, Korea. Her research interests include Internet communications and statistical modeling of communication networks traffic.

E-mail address: diana@inhatec.ac.kr