

사용자 행동 패턴 선호도 학습을 위한 퍼지 귀납 학습 시스템

Fuzzy Inductive Learning System for Learning Preference of the User's Behavior Pattern

이형욱^{*} · 김용희^{*} · 박광현^{*} · 김용수^{**} · 정진우^{***} · 조준면^{****} · 김민경^{****} · 변증남^{*}

Hyong-Euk Lee, Yong-Hwi Kim, Kwang-Hyun Park, Yong-Su Kim, Jin-Woo Jung,
Joonmyun Cho, MinGyoung Kim and Z. Zenn Bien

* 한국과학기술원 전자전산학과

** 대전대학교 컴퓨터 공학부

*** 한국과학기술원 인간친화복지로봇시스템연구센터

**** 한국전자통신연구원 지능로봇연구단

요약

본 논문은 스마트 홈과 같이 다양한 센서 및 제어 네트워크가 밀집되어 있는 유비쿼터스 환경 하에서 복잡한 인터페이스의 사용에 대한 사용자의 인지 부담(cognitive load)을 줄이고, 개인화된(personalized) 서비스를 자율적으로 제공하기 위한 새로운 사용자 행동 패턴 선호도 학습 기법을 제안한다. 이를 위해 지식 발견(knowledge discovery)을 위한 평생 학습(life-long learning)의 관점에서 퍼지 귀납(fuzzy inductive) 학습 방법론을 제안하며, 이것은 수치 데이터로부터 입력 공간에 대한 효율적인 퍼지 분할(fuzzy partition)을 얻어내고 일관성 있는(consistent) 퍼지 상관 룰(fuzzy association rule)을 얻어내도록 한다.

Abstract

Smart home is one of the ubiquitous environment platforms with various complex sensor-and-control network. In this paper, a new learning methodology for learning user's behavior preference pattern is proposed in the sense of reducing user's cognitive load to access complex interfaces and providing personalized services. We propose a fuzzy inductive learning methodology based on life-long learning paradigm for knowledge discovery, which tries to construct efficient fuzzy partition for each input space and to extract fuzzy association rules from the numerical data pattern.

Key Words : 퍼지 귀납 학습, 지식 발견, 유비쿼터스 환경, 행동 패턴 학습, 평생 학습

1. 서 론

유비쿼터스 환경(ubiquitous environment)은 다양한 센서 네트워크(sensor network)와 컴퓨팅 컴포넌트(computing component)들이 환경 내에 보이지 않게 스며들어 밀집되어 있는 복잡한 시스템으로 해석될 수 있다. 그리고 이러한 유비쿼터스 환경의 대표적인 예로는 스마트 홈(smart home)을 들 수 있다.

스마트 홈은 사용자와 환경을 모니터링 할 수 있는 다양한 센서(예. 온습도 센서, 인체감지센서, 비전 센서 등)들과 가전 기기(예. 텔레비전, 에어컨, 조명 등), 서비스 로봇 등과

같은 여러 가지 제어 가능한 디바이스(device)들이 한 곳에 집약되어 있는 복잡한 시스템이다.

스마트 홈과 관련된 연구에서 중요한 이슈 중의 하나는 바로 사용자의 편의성이다. 특히 노약자, 장애인들에 대한 사회적 관심이 높아지고, 사회가 점점 고령화됨에 따라서 사용자로 하여금 얼마나 쉽고 편리하게 다양한 서비스를 누릴 수 있도록 하는가는 중요한 문제로 떠오르게 되었다. 이를 위하여 보다 쉽고 편리하게 복잡한 다기능의 디바이스들을 제어 할 수 있도록 인간-기계 인터페이스를 개발하는 다양한 연구들이 이루어지고 있다. 하지만, 여전히 복잡한 제어 대상들에 대해 특화된 각각의 인터페이스는 사용자로 하여금 인지 부담을 가중시킨다는 단점을 가지고 있다.

때문에 스마트 홈 환경에서 보다 자연스럽고 인간친화적인 제어 환경을 구축하기 위하여 사용자의 의도 파악(intention reading) 기술의 개발에 대한 관심이 높아지고 있으며, 이러한 의도 파악 기술의 요소 기술 중에서도 기계 학습 능력(machine learning capability)에 대한 연구는 중요한 분야로 자리매김한다.

본 논문에서는 스마트 홈 환경에서 기계 학습 능력에 기

접수일자 : 2005년 10월 21일

완료일자 : 2005년 12월 5일

감사의 글 : 본 연구는 한국전자통신연구원 지능형 로봇사업단의 지원으로 수행되었음.

본 연구는 과학기술부/한국과학재단 우수연구센터 육성 사업의 지원으로 수행되었음
(R11-1999-008)

반하여 사용자 의도 파악 기술을 구현하는 응용 사례의 하나로, 퍼지 귀납 학습 방법을 이용한 사용자 행동 패턴 학습 기법을 제안한다.

본문에서는 먼저 관련 연구로서 생활 패턴 학습 기능을 가진 스마트 홈의 사례들을 분석한다. 그리고 이를 바탕으로 지식 발견과 평생 학습 개념의 측면에서 필요한 기능에 대해 기술하며, 이를 위한 퍼지 귀납 학습 시스템의 구조 및 학습 과정에 대해서 서술한다. 그리고 정보 제공 서비스를 위한 생활 패턴 데이터에 대한 시뮬레이션 결과를 통해 효용성을 보이도록 한다.

2. 배경 지식

2.1 관련 연구

스마트 홈 환경에서 사용자 행동 패턴 학습 시스템을 개발한 사례로는 대표적으로 어댑티브 하우스(Adaptive House, University of Colorado)[1]와 아이돔(iDorm, University of Essex)[2]을 들 수 있다. 어댑티브 하우스에서는 인공 신경망(Artificial Neural Network)을 이용한 최적 제어 기법에 기반하여 에너지 비용(energy cost)과 사용자 불편 비용(discomfort cost)을 최소화 하도록 온도, 조명과 같은 환경을 제어하는 방법이 제안되었다. 또한 아이돔에서는 퍼지 룰 기반의 점진적 학습 방법(incremental learning method)을 사용하여 환경 정보에 따른 사용자의 다양한 가전 기기 제어 명령 패턴을 학습하여 제어에 응용하는 방법이 제안되었다.

인공신경망은 패턴 인식 및 분류(pattern recognition and classification) 분야에서 성공적으로 적용된 많은 사례를 가지고 있다. 하지만, 인공 신경망은 학습된 지식이 뉴런 사이의 수치화된 가중치(weight)로 표현이 되기 때문에 해석하기가 어렵다는 단점을 가지고 있어 부분적인 지식의 수정을 어렵게 한다. 특히 생활 패턴과 같은 데이터는 시간이 지남에 따라 변화할 수 있고 이에 맞추어서 지속적으로 적용 학습을 해야 하기 때문에, 해석 가능한 지식의 형태로 저장되어야 보다 효율적인 정보 관리가 가능해진다.

반면에 퍼지 논리(fuzzy logic) 기반의 지식화 기법은 퍼지 집합의 개념을 이용하여 불확실성(uncertainty)을 가진 데이터들을 효율적으로 처리할 수 있으며 IF-THEN 룰을 이용하여 사람이 생각하는 방식으로 지식화를 할 수 있다는 측면에서 재해석 및 지식의 수정이 용이하다는 장점을 가진다. 하지만 아이돔에서 사용된 퍼지 룰 기반의 학습 방식은 통상적인 퍼지 제어 시스템에서 이용된 것과 같이 입력 공간(input space)에 대한 퍼지 분할을 사전 지식(prior-knowledge)을 이용하여 미리 할당해 두고 룰을 얻어내는 방식을 취하기 때문에, 개인차 및 부정확한 사전 지식에 따라 잘못된 룰들이 얻어질 수 있다는 제한점을 가지고 있다.

2.2 지식 발견을 위한 평생 학습

데이터베이스(database)에서의 지식 발견은 데이터로부터 의미 있고 유용하며 궁극적으로 이해 가능한 패턴을 얻어내는 논트리비얼 과정(non-trivial process)으로 간단히 정의된다[3]. 이 때 지식의 형태는 응용 분야에 따라 여러 가지 형태로 정의가 될 수 있다. 하지만 본 논문에서는 2.1절에서 설명한 것과 같이 보다 세부적으로 생활 패턴 학습과 관련한 지식 발견의 의미를 데이터 패턴의 분포에 따라 각 입력 공

간에 대한 퍼지 분할을 자율 구성(self-construction)하고, 그에 상응하는 일관성있는 퍼지 상관 룰을 얻어내는 것으로 재정의하여 사용하도록 한다.

이와 같이 생활 패턴 데이터로부터 지식 발견 과정에서 또 하나 중요하게 생각해야 하는 부분은 평생 학습 패러다임(paradigm)에 기반한 학습 시스템이어야 한다는 것이다. 기존의 패턴 인식 문제와 달리 생활 패턴과 같은 데이터는 단기간에 얻어지기 힘들며, 시간이 지남에 따라 변화할 수 있다는 특성을 가진다. 이러한 관점에서 평생 학습의 중요성이 부각되며, 평생 학습은 지속 학습(continuous learning)으로도 불리며, 시스템의 수명 기간 동안 끊임없이 학습하는 것을 강조한다[4].

본 논문에서는 지식 발견을 위한 평생 학습의 개념을 귀납적 학습 과정(inductive learning process)과 연역적 학습 과정(deductive learning process)을 끊임없이 반복하면서 일관성 있는 지식을 추출해 내는 것으로 재해석하여 사용한다. 생활 패턴 학습에서 귀납적 학습 과정은 사용자의 행동 패턴에 대한 모니터링(monitored)을 통해 훈련(training)할 데이터 패턴을 얻고 이를로부터 지식화하는 과정을 의미한다. 그리고 연역적 학습 과정은 귀납적 학습 과정을 통해 얻어진 지식을 이용하여 사용자에게 서비스를 제공하고 사용자로부터 리워드(reward)/페널티(penalty)와 같은 피드백(feedback) 신호를 받아 지식을 보강 또는 수정하는 과정을 의미한다. 그럼 1은 이러한 과정을 도식화하여 나타낸 것이다. 여기서 학습 페이즈(phase) I은 귀납 학습 과정을 말하며 학습 페이즈 II는 연역 학습 과정을 의미한다. 그리고 본 논문에서는 위에서 언급한 두 과정 중에서 귀납적 학습 기법에 대해서 다루도록 한다.

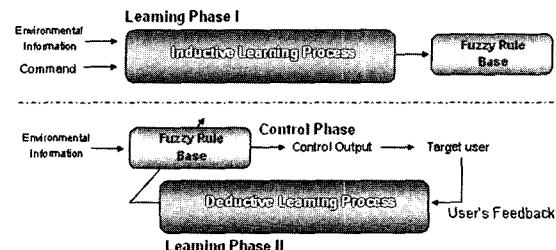


그림 1. 지식 발견을 위한 퍼지 평생 학습 시스템 구조
(사용자 행동 패턴 학습 및 제어)

Fig. 1. Structure of Life-long Learning System for Knowledge Discovery
(User's Behavior Pattern Learning and Control)

3. 퍼지 귀납 학습 시스템

3.1 전체 시스템 구조

그림 2는 퍼지 귀납 학습 시스템의 전체 구조를 나타내고 있다. 퍼지 귀납 학습 시스템의 입력은 훈련을 위한 데이터 패턴이 되고 출력은 제어를 포함한 연역 학습 과정을 위한 퍼지 룰 기반(fuzzy rule base)이 된다.

퍼지 귀납 학습 과정은 다시 데이터 레벨(data-level) 퍼지 귀납 학습과 룰 레벨(rule-level) 퍼지 귀납 학습 과정으로 나뉜다. 데이터 레벨 퍼지 귀납 학습 과정은 주어진 수치 데이터를 상응하는 퍼지 집합과 퍼지 룰로 나타내는 과정을 의미하며, 룰 레벨의 퍼지 귀납 학습은 데이터 레벨 퍼지 귀

납 학습 과정으로부터 얻어진 퍼지 집합과 퍼지 룰을 지식 발견을 위하여 효율적으로 통합, 선택하고 일관성 있는 룰을 얻어내는 과정을 말한다.

퍼지 귀납 학습 과정은 이러한 과정을 다루기 위해서 전체 학습 과정을 세 단계로 나누어 진행하게 되며 이것은 각각 단기 메모리(short-term memory)에서의 학습과정, 전환 메모리(transition memory)에서의 학습 과정, 장기 메모리(long-term memory)에서의 학습 과정을 말한다. 그리고 단기 메모리에서의 학습 과정은 데이터 레벨의 귀납 학습이 이루어지며, 장기 메모리에서는 룰 레벨의 귀납학습이 이루어지게 된다.

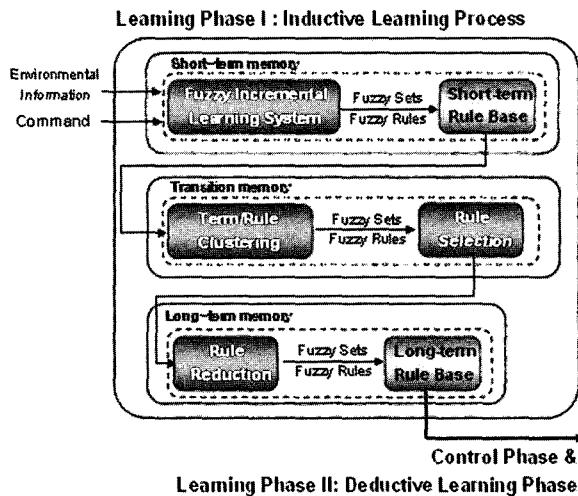


그림 2. 퍼지 귀납 학습 시스템 전체 구조
Fig. 2. Overall Structure of Fuzzy Inductive Learning System

3.2 단기 메모리에서의 학습 과정

단기 메모리에서는 퍼지 중분 학습 시스템 FILS (Fuzzy Incremental Learning System)[5]을 이용하여 MISO (multi-input multi-output) 형태를 가지는 입출력 훈련 데이터로부터 퍼지 집합과 퍼지 룰을 추출하는 데이터 레벨의 귀납 학습이 이루어진다. 그림 3은 FILS의 학습 과정을 도식화 한 것이다.

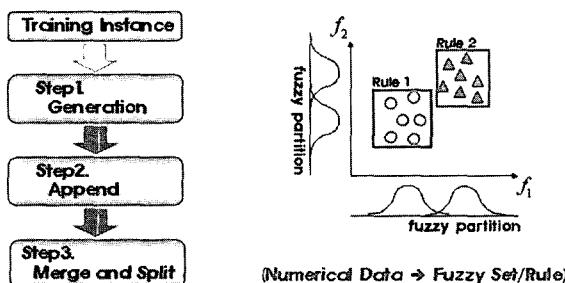


그림 3. FILS 학습 과정
Fig. 3. FILS Learning Procedure

학습 과정은 점진적으로 일어나며, 퍼지 룰은 다차원의 입력 공간에 대해서 하이퍼박스(hyperbox)의 형태로 얻어진다. 전체적인 학습 과정은 퍼지 최소-최대 신경망(Fuzzy Min-

Max Neural Network) [6]과 유사하나 점진적 학습 과정의 문제점으로 잘 알려진 데이터 순서 영향 (data-order dependency)을 줄이기 위해서 병합(merging)과 분할(splitting) 과정을 거치도록 수정되었다. 이를 위해서 하이퍼박스화된 퍼지룰을 형성하는 전건부(antecedent part)의 퍼지 집합의 크기를 조절하는데 통계적인 회귀 계산(statistical recursive calculation)을 이용하게 되며, 출력값은 이산화(discretized) 되었다고 가정한다. 또한 어떤 어떤 입력 특성(attribute) x_i 의 퍼지 분할 $T(x_i)$ 가 $T(x_i) = \{T_i^1, T_i^2, \dots, T_i^k\}$ 로 표현되고 T_i^k 는 $T(x_i)$ 의 k 번째 퍼지 집합이라고 할 때, T_i^k 를 형성하는 수치 데이터들의 통계적 특성이 평균 $m_{T_i^k}$ 와 표준 편차 $\sigma_{T_i^k}$ 를 갖는다고 하면 소속 함수(membership function) $\mu_{T_i^k}$ 는 식 (1)과 같은 가우시안(Gaussian) 형태의 함수로 표현할 수 있으며, 이를 이용해서 분할 과정에서 데이터의 분포를 재해석 할 경우, $a = e^{-1} - cut$ 구간 안에서 균일하게 분포(uniform distribution)되어 있다고 가정한다.

$$\mu_{T_i^k} = e^{-(x - m_{T_i^k})^2 / (\sigma_{T_i^k}^2)} \quad (1)$$

3.2 전환 메모리에서의 학습 과정

전환 메모리에서는 단기 학습 과정에서 얻어진 퍼지 집합과 퍼지 룰들을 효과적으로 통합, 선택하여 장기 학습 메모리로 옮기는 학습 과정이 이루어진다. 단기 메모리의 FILS를 통해 얻어진 퍼지 집합과 퍼지 룰은 분류해야 할 클래스(class)간 겹침(overlap)이 없도록 데이터에 따라 병합과 분할 과정을 반복하기 때문에, 각 입력 축의 관점에서 비일관적인 데이터 패턴이 보일 경우 퍼지 집합과 하이퍼박스에 대한 분할이 늘어난다는 단점을 가지고 있다(그림 4).

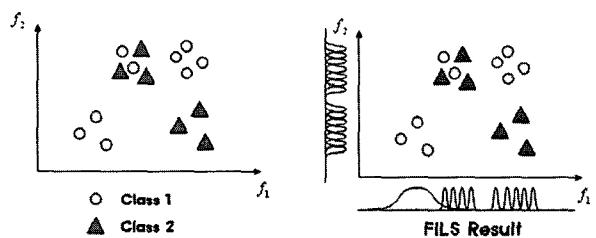


그림 4. 비일관적인 데이터가 혼합되어 있는 경우의 FILS 학습 결과
Fig. 4. FILS Learning Result with Inconsistent Data Pattern

때문에 위와 같이 불필요하게 분할된 퍼지 집합들과 하이퍼박스를 클러스터링(clustering) 기법을 이용하여 효율적으로 묶어 주는 과정은 지식 발견을 위해서도 중요한 과정이 된다. 그림 5는 클러스터링 과정을 통해서 비일관적인 룰들을 제거하고 일관성 있는 지식을 얻어내는 과정을 도식화 한 것이다.

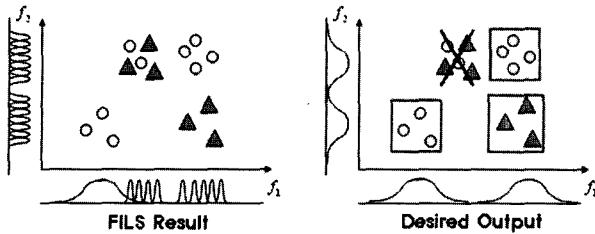


그림 5. 클러스터링과 일관성 있는 룰의 선택
Fig. 5. Clustering and Consistent Rule Selection

그림 6과 그림 7은 전환 메모리에서 클러스터링 과정을 나타낸 것이다. 그림 6은 각 클래스에 대한 하이퍼박스 클러스터링 과정을 도식화 한 것이며, 그림 7은 이에 대한 과정을 나타난 것이다.

본 논문에서의 클러스터링 과정은 간단히 유кли디안 거리(Euclidean distance)를 이용하여 정렬하고 반복 밀도(density)에 기반하여 병합을 하는 과정으로 요약할 수 있다. 클러스터링 과정은 각 클래스에 대해서 독립적으로 수행된다. 어떤 클래스에 대해서 형성된 N 개의 하이퍼박스는 각각 $r_1 \sim r_N$ 으로 표현된다. 그리고 c_k , $Freq_k$ 는 각각 r_k 의 중앙값과 데이터의 반복 학습된 수로 정의하고, 입력 공간에서의 각 하이퍼박스의 넓이 A_k 및 밀도 Den_k 는 M개의 입력에 대해서 다음과 같이 정의 한다.

$$A_k = \prod_{i=1}^M 2\sqrt{3}\sigma_k, Den_k = Freq_k/A_k \quad (2)$$

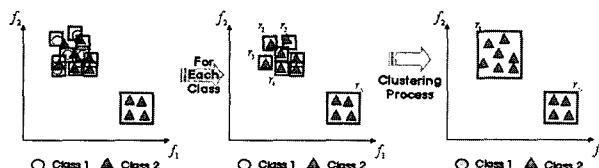


그림 6. 전환 메모리에서의 클러스터링 과정
Fig. 6. Clustering Process in Transition Memory

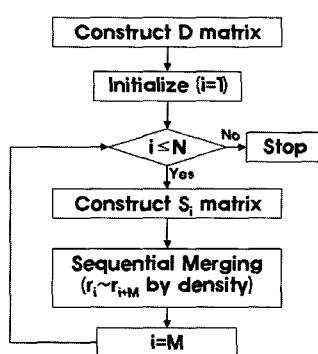


그림 7. 전환 메모리에서의 학습 과정
Fig. 7. Learning Process in Transition Memory

먼저 하이퍼박스간의 거리에 의해서 D 행렬(matrix)을 다음과 같이 계산한다. 이 때, $d_{ij} = |c_i - c_j|$ 이다.

$$D = \begin{bmatrix} 0 & 1 & 2 & \dots & N \\ 1 & d_{11} & d_{12} & \dots & d_{1N} \\ 2 & d_{21} & d_{22} & \dots & d_{2N} \\ \dots & \dots & \dots & \dots & \dots \\ N & d_{N1} & d_{N2} & d_{N3} & d_{NN} \end{bmatrix} \quad (3)$$

D 행렬의 첫 번째 행(row)과 열(column)은 각 하이퍼박스 인덱스(index)를 의미한다. 식 (4)의 S_i 행렬은 반복 과정에서 바로 이전의 S 행렬의 $(i+1)$ 행의 값에 기준하여 $(i+1)$ 열부터 오름차순으로 정렬한 값이다. 이 때, $S_0 = D$ 이다.

$$S_i = \begin{bmatrix} 0 & 1 & \dots & l_{i+k} & \dots & l_N \\ 1 & d_{11} & \dots & d_{1l_{i+k}} & \dots & d_{1l_N} \\ 2 & d_{21} & \dots & d_{2l_{i+k}} & \dots & d_{2l_N} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ N & d_{N1} & \dots & d_{Nl_{i+k}} & \dots & d_{Nl_N} \end{bmatrix} \quad (4)$$

S_1 에서는 $d_{11} \leq \dots \leq d_{1l_{i+k}} \leq \dots \leq d_{1l_N}$ 의 관계를 가지고 첫 번째 행은 r_1 부터 가까운 순서대로의 하이퍼박스 인덱스를 의미한다. r_i 와 r_j 가 병합되었을 때 병합된 반복 밀도 $Den_{Acc}(r_i, r_j)$ 는 다음과 같이 정의된다.

$$Den_{Acc}(r_i, r_j) = (Freq_i + Freq_j)/A_{Acc}(r_i, r_j), \quad A_{Acc}(r_i, r_j) = \frac{1}{M} |\max(c_i^f + \sqrt{3}\sigma_i^f, c_j^f + \sqrt{3}\sigma_j^f) - \min(c_i^f - \sqrt{3}\sigma_i^f, c_j^f - \sqrt{3}\sigma_j^f)| \quad (5)$$

식 (5)에서 M 개의 입력 정보에 대해서 c_i^f 및 σ_i^f 는 각각 c_i , σ_i 벡터의 f 번째 값을 의미한다.

S_i 행렬의 첫 번째 행을 따라서 $(i+1)$ 열의 인덱스에 해당하는 하이퍼박스($= r_{S_i^{1,(i+1)}}$)부터 순차적으로 병합을 시행한다. 병합 조건을 만족하여 병합이 된 하이퍼박스를 r_{prev} 라고 할 때, $r_{prev} = r_{S_i^1}$ 로 초기화하면 병합 과정은 다음의 과정을 만족할 때까지만 수행하고 다시 다음 S 행렬을 계산하도록 한다.

$$|Den_{Acc}(r_{prev}, r_{S_i^{1,(i+1)}}) - Den_{S_i^1}| < \alpha Den_{S_i^1} \quad (6)$$

즉, 병합을 했을 때의 반복 밀도가 병합을 시작하는 하이퍼박스의 밀도를 기준으로 일정 비율 이내의 것을 같은 클러스터로 간주하게 된다. 이러한 과정은 $r_1 \sim r_N$ 까지 모든 하이퍼박스에 대해서 수행되고 종료하게 된다. 이후 클러스터링 된 각각의 하이퍼박스에 대한 사영(projection)으로 각 입력 공간에 대한 퍼지 집합을 병합하는 것으로 퍼지 분할을 재수정한다.

3.3 장기 메모리에서의 학습 과정

장기 메모리에 저장된 퍼지 분할과 퍼지 룰들은 제어 및 연역 학습 과정을 위해 사용되는 지식으로서 지속적으로 누적되고 변화, 삭제가 이루어진다. 때문에 장기 메모리에서의 학습은 단기 메모리에서의 학습 과정과 같이 점진적으로 이루어지며, 룰 기반의 귀납 학습이 이루어진다.

전환 메모리에서의 학습과정을 거친 하이퍼박스는 장기 메모리에 있는 퍼지 분할과 룰들과의 비교를 통해서 장기 메모리에 추가/수정 여부가 결정된다. 그림 8은 장기 메모리에서의 학습 과정을 나타낸 것이다.

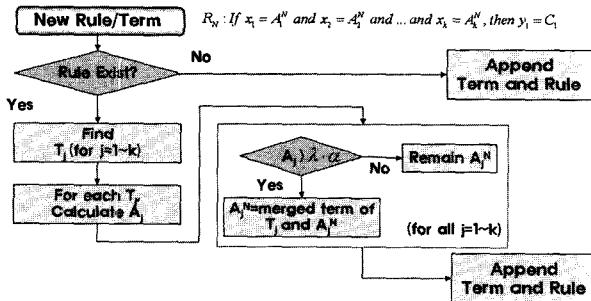


그림 8. 장기 메모리에서의 학습 과정
Fig. 8. Learning Process in Long-term Memory

전환 메모리로부터 새로 들어온 하이퍼박스는 다음의 룰로 표현된다.

$$R_N : \text{If } x_1 = A_1^N \text{ and } x_2 = A_2^N \text{ and } \dots \text{ and } x_k = A_k^N, \text{ then } y_i = C_i \quad (7)$$

이 때, $d_{a-cut}(T)$ 는 퍼지 집합 T 의 $a-cut$ 길이를 의미하고, 그림 8에서 $a = \min(d_{a-cut}(T_i), d_{a-cut}(A_i^N))$ 으로 정의된다. 그리고 T_i 는 장기 메모리의 i 번째 입력 특성(attribute)에 대한 퍼지 분할을 형성하는 퍼지 집합 중에서 퍼지 집합 A_i^N 과 $a-cut$ 이 겹치는 것 중 가장 가까운 퍼지 집합을 의미한다. 그리고 A_i 는 T_i 와 A_i^N 의 겹쳐진 $a-cut$ 의 길이를 의미한다.

장기 메모리에 저장된 룰이 없을 경우 새로 들어온 룰은 그대로 저장이 된다. 하지만 장기 메모리에 룰이 존재할 경우 그림 8의 순서도에 보이는 것과 같이, 각각의 입력 특성(attribute)에 대해서 가장 가까운 퍼지 집합을 선택하고 중첩도를 판별한다. 그리고 중첩도가 높을 경우 선택된 장기 메모리의 퍼지 집합과 새로운 퍼지집합을 병합하여 수정하게 된다. 새로 들어온 퍼지 룰의 모든 특성에 대한 퍼지 분할과의 중첩도 비교를 마친 후 장기 메모리의 퍼지 룰 기반에 추가가 되며, 이 때 중복되는 룰은 제거하게 된다.

이 과정은 전환메모리로부터 넘어온 모든 하이퍼박스에 대해서 순차적으로 이루어진다.

4. 시뮬레이션 결과

그림 9는 스마트 홈 환경에서 정보 제공 서비스가 사용자에게 어떤 식으로 활용될 수 있는지에 대한 하나의 시나리오를 보여주고 있다.

학습 엔진은 시간과 사용자의 위치에 따라 날씨(지역별), 일반 정보(정치, 경제, 연예 등)와 같은 사용자의 명령 패턴을 학습하고, 소프트웨어 로봇을 통해서 사용자의 선호도에 맞는 정보를 제공할 수가 있게 된다.

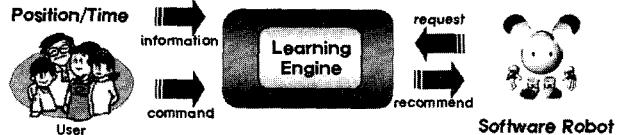


그림 9. 소프트웨어 로봇을 이용한 정보 제공 서비스
Fig. 9. Information Providing Service using Software Robot

그림 10과 11은 시간과 사용자의 위치에 따른 정보 서비스 패턴을 도식화 한 것이다.

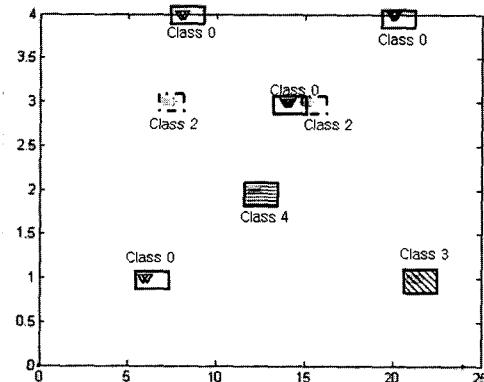


그림 10. 정보 제공 서비스 패턴 1
Fig. 10. Information Providing Service Pattern 1

이 때, $x (= x_1)$ 축은 시간을 의미하고, $y (= x_2)$ 축은 이산화된 사용자 위치의 번호를 의미한다. 그리고 각 클래스는 사용자가 어떤 종류의 서비스(정치, 경제, 연예/스포츠 등)를 요구했는지를 의미한다. 이러한 가상의 시나리오에 대하여 그림 10의 패턴은 각 클래스간 겹침이 없는 경우를 의미하고, 그림 11의 패턴은 어느 정도의 클래스간 겹침이 있는 경우를 의미한다.

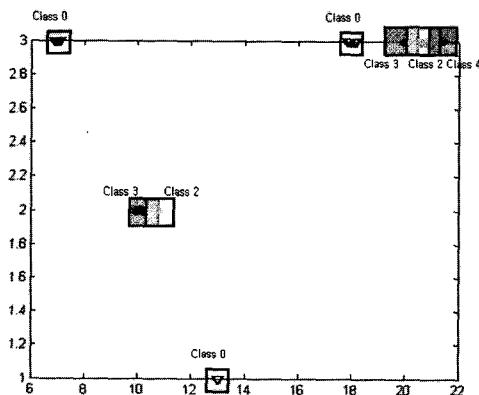


그림 11. 정보 제공 서비스 패턴 2
Fig. 11. Information Providing Service Pattern 2

이러한 패턴에 대해서 퍼지 귀납 학습 시스템을 적용하게 되면, 다음과 같은 결과를 얻을 수 있다. 그림 12는 그림 10과 그림 11의 패턴에 대한 장기 메모리의 퍼지 분할을 도식화한 것이다. 그리고 표 1은 그림 10과 그림 11의 패턴에 대

한 단기 메모리, 장기 메모리에서의 학습 결과를 나타낸 것이며, 표 2는 전환 메모리에서 얻어진 클래스별 클러스터 수를 의미한다.

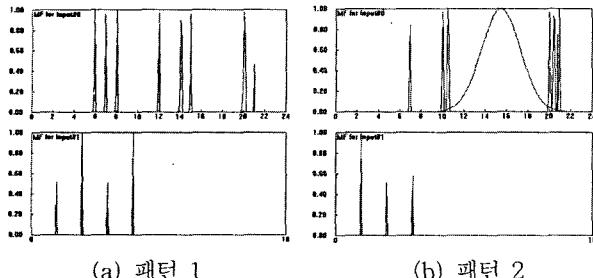


그림 12. 장기 메모리의 퍼지 분할

Fig. 12. Fuzzy Partition in Long-term Memory

표 1. 단기/장기 메모리에서의 학습 결과

Table 1. Learning Result in Short/Long-term Memory

		$N(x_1)$	$N(x_2)$	N
패턴 1	단기메모리	8	34	41
	장기메모리	8	5	10
패턴 2	단기메모리	11	50	52
	장기메모리	10	4	12

이 때 $N(x_1)$ 및 $N(x_2)$, N은 각각 x_1 과 x_2 에 대한 퍼지 분할의 퍼지 집합 수와 얻어진 퍼지 룰의 수를 의미한다. 결과에서 볼 수 있듯이 각각의 패턴에 대해서 단기 메모리에서 불필요하게 분할된 하이퍼박스는 장기 메모리에서 병합이 되어 퍼지 분할을 형성하는 퍼지 집합의 수 및 퍼지 룰의 수가 줄어든 것을 볼 수 있으며, 분류(classification)에 문제가 없는 퍼지 집합은 병합 과정을 통해서 일반화를 하고 있음을 볼 수 있다. 그러나 병합 과정에서 병합 조건을 만족하지 않을 때에는 패턴 1의 경우와 같이 장기 메모리에서의 퍼지 집합 수가 늘어날 수는 있음을 알 수 있다. 즉 그림 9에서 클래스 2에 대한 클러스터링 과정을 거칠 경우, 사람이 판단하기에는 2개의 클러스터로 분할 하는 것이 적절하나, 시스템에서는 단기 메모리를 거쳐서 나온 하이퍼박스들을 4개의 클러스터로 판단을 하게 된다.

표 2. 전환 메모리에서의 클러스터링 결과

Table 2. Clustering Result in Transition Memory

클러스터수	Class0	Class1	Class2	Class3	Class4
패턴 1	4	0	4	1	1
패턴 2	5	0	6	3	4

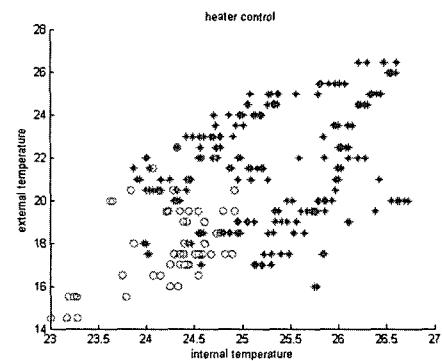


그림 13. 온도에 따른 에어컨 제어 패턴

Fig. 13. Air-conditioner Control Pattern according to internal/external temperature

그림 13은 실내/외 온도에 따른 에어컨의 온/오프(On/Off) 제어에 대한 패턴의 예를 보여주고 있다. 마찬가지로 이러한 패턴을 퍼지 귀납 학습 시스템을 통해 시뮬레이션했을 경우 표 3과 같은 결과를 얻을 수 있다.

표 3. 단기/장기 메모리에서의 학습 결과

Table 3. Learning Result in Short/Long-term Memory

	$N(x_1)$	$N(x_2)$	N
단기메모리	111	72	288
장기메모리	2	2	2

이러한 패턴의 경우, 클래스간 겹침 현상을 고려해도 사용자의 행동 패턴은 2개의 룰로 간단히 해석 가능함을 알 수 있다.

5. 결 론

지식 발견을 위한 평생 학습의 개념은 스마트 홈 환경에서 사용자의 행동 패턴을 학습하는 시스템에 응용될 수 있으며, 퍼지 귀납 학습 기법은 주어진 수치 데이터 패턴으로부터 일관성 있는 퍼지 분할과 퍼지 상관 룰을 효율적으로 얻어낼 수 있도록 해준다.

본 논문에서는 이러한 퍼지 귀납 학습 기법을 세 단계로 나누어 단기 메모리에서의 학습 과정, 전환 메모리에서의 학습 과정과 장기 메모리에서의 학습 과정을 거쳐 훈련 패턴을 지식화 하는 방법에 대해 제안하였다.

하지만 지식 발견을 위한 평생 학습의 개념에서 퍼지 귀납 학습 기법은 제어 및 연역적 학습과 연계하는 것이 필요하며, 입력 공간의 차원을 줄이기 위한 특정 집합 선택(feature subset selection) 알고리즘 또한 고려되어야 한다.

그리고 시스템의 신뢰도와 효용성 검증을 위하여 보다 많은 대상 사용자에 대한 실제 생활 패턴 데이터의 시뮬레이션 결과 분석이 요구된다.

참 고 문 현

- [1] Mozer, M. C., "The neural network house: An environment that adapts to its inhabitants", Proc. of the American Association for Artificial Intelligence

- Spring Symposium on Intelligent Environments, Menlo, Park, pp. 110–114, 1998
- [2] H. Duman, V. Callaghan, H. Hagras, M. Colley, G. Clarke, Z. Bien, H. Lee, Y. Kim, "A Multi-Agent Pervasive Computing Architecture For Geographically Dispersed Care Environments" Proceedings of the 10th International Fuzzy Systems Association World Congress (IFSA 2003), Turkey, 2003
- [3] U. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "From Data Mining to Knowledge Discovery: An Overview", in Advances in Knowledge Discovery and Data Mining, MIT Press, Cambridge, Mass., pp. 1–36.1996
- [4] Fred H. Hamker, "Life-long learning Cell Structures-continuously learning without catastrophic interference", IEEE Trans. Neural Networks, Vol. 14, 2001
- [5] Hyong-Euk Lee and Z. Zenn Bien, "Inductive Learning Structure for Knowledge Discovery in Ubiquitous Environment", Proceedings of Int'l Symposium on Advanced Intelligent Systems, Korea, pp. 258–262, 2005,
- [6] P.K. Simpson, "Fuzzy min-max neural networks-Part 1: Classification", IEEE Trans. Neural Network, vol. 3, pp.776–786, 1992

저 자 소 개

**이형욱(Lee Hyong-Euk)**

2000년 : 한국과학기술원 전자전산학과 학
사과정 졸업
2002년 : 동 대학원 전자전산학과 석사과정
졸업
2002년~현재 : 동 대학원 전자전산학과
박사과정

관심분야 : 퍼지이론, 학습이론, 지식발견, 유비쿼터스 환경,
지능로봇

Phone : 042-869-8019
Fax : 042-869-8750
E-mail : helee@ctrssys.kaist.ac.kr

**김용희(Kim Yong-Hwi)**

2005년 : 세종대학교 전자공학과 학사과정
졸업
2005년~현재 : 한국과학기술원 전기 및
전자공학과 석사과정

관심분야 : 학습이론, 패턴인식, 지능로봇
Phone : 042-869-5419

Fax : 042-869-8750
E-mail : kyh8301@ctrssys.kaist.ac.kr

**박광현(Park Kwang-Hyun)**

1994년 : 한국과학기술원 전자전산학과 학
사과정 졸업
1997년 : 동 대학원 전자전산학과 석사과정
졸업
2001년 : 동 대학원 전자전산학과 박사과정
졸업
2005년~현재 : 한국과학기술원 전자전산
학과 BK 초빙교수

관심분야 : 학습이론, 지능로봇, 인간-로봇 상호작용, 재활공학
Phone : 042-869-5419
Fax : 042-869-8750
E-mail : akaii@robotian.net

**김용수(Kim Yong-Su)**

1981년 : 연세대학교 전기공학과 학사 과정
졸업
1983년 : 학국과학기술원 전기 및 전자공학
과 석사과정 졸업
1986년 : 삼성전자 종합연구소 주임연구원
1993년 : Dept. of Electrical Eng., Texas
Tech Univ. 박사 과정 졸업
1995년~현재 : 대전대학교 컴퓨터공학부 부교수

관심분야 : 신경회로망, 퍼지 논리, 패턴인식, 영상처리, 침입
탐지 시스템 등
Phone : +82-42-280-2547
Fax : +82-42-284-0109
E-mail : kystj@dju.ac.kr

**정진우(Jung Jin-Woo)**

1997년 : 한국과학기술원 전기 및 전자공학
과 학사과정 졸업
1999년 : 동 대학원 전기 및 전자공학과 석
사과정 졸업
2001년~2002년 : 일본 동경대학교 기계정
보공학과 대학원 방문연
구원
2004년 : 동 대학원 전자전산학과 박사과정 졸업
2004년~현재 : 한국과학기술원 인간친화 복지 로봇시스템
연구센터 박사 후 연구원

관심분야 : 행동기반 생체인식, 인간-로봇 상호작용, 소프트
컴퓨팅
Phone : +82-42-869-8415
Fax : +82-42-869-8750
E-mail : jinwoo@ctrssys.kaist.ac.kr

**조준면(Cho Joon-Myun)**

1993년 : 한국과학기술원 기계공학과 학사
과정 졸업
1995년 : 동 대학원 자동화 설계 공학과 석
사과정 졸업
1995년~2001년 : (주)불보건설기계코리아 기
술연구소 (구 삼성중공업
중앙연구소) 선임연구원

2001년~현재 : 한국과학기술원 기계공학과 박사과정

관심분야 : Ontological Engineering, Knowledge Engineering,
지능형 정보 시스템

Phone : 042-860-1873

Fax : 042-860-6790

E-mail : jrncho@etri.re.kr



변증남(Bien Z. Zenn)

1969년 : 서울대학교 전자공학과 학사과정
졸업

1972년 : University of Iowa 전자공학과
석사과정 졸업

1975년 : University of Iowa 수학과 석사
과정 졸업

1975년 : University of Iowa 전자공학과
박사과정 졸업

1976년~1977년 : University of Iowa 조교수

1981년~1982년 : University of Iowa 객원부교수

1987년~1988년 : Syracuse University, New York, USA
객원 연구원

1988년 : 일본 동경공대 객원 교수

1990년~1995년 : 한국 퍼지 및 지능 시스템 학회장

2003년~2005년 : 국제퍼지시스템학회(IFSA) 회장

1977년~현재 : 한국과학기술원 전기및전자공학과 교수

1999년~현재 : 한국과학기술원 인간친화복지로봇연구센터
소장

2003년~현재 : 한국로봇공학회 회장

2005년~현재 : 한국전력 석좌교수

관심분야 : 지능제어, 학습이론, 소프트컴퓨팅, 퍼지이론, 서
비스로봇

Phone : +82-42-869-3419

Fax : +82-42-869-8410

E-mail : zbiens@ee.kaist.ac.kr



김민경(Kim Min-Gyoung)

1998년 : 이화여자 대학교 컴퓨터학과 학사
과정 졸업

1998년~2001년 : 데이콤 천리안 개발 연
구팀 연구원

2004년 : University of Southern California,
Los Angeles, CA Computer
Science 석사과정 졸업

2004년~2005년 : 삼성전자 디지털 미디어 연구소 선임 연구원

2005년~현재 : 한국전자통신연구원 지능형로봇연구단 연구원

관심분야 : 지능로봇

Phone : +82-42-860-1838

Fax : +82-42-860-6790

E-mail : bluet9@etri.re.kr