지능제어: 정체성 고찰과 주요 기법의 전망

Intelligent Control: Its Identity and Some Noticeable Techniques

변 증 남*, 서 일 홍
 (Z. Zenn Bien^{1,*} and Il Hong Suh²)

¹Department of Electrical Engineering, KAIST

²Department of Electronic Engineering, Hanyang University

Abstract: Referring to various definitions, we first examine the identity issue of intelligent control and, have tried to explain the nature and attributes of intelligent control in terms of two categories of positions, that is, the Noumenalist's position and the Phenomenologist's position. And then, we give detailed descriptions for (1) FUZZY-based intelligent control and (2) learning control. Finally, as a noticeable new technique of intelligent control for robotic applications, we present (3) Cognitive control.

Keywords: intelligent control, FUZZY-based control, learning control, cognitive control

I. 서론

제어대상이 비선형성, 시변성 또는 구성요소간 복잡한 상호연결성 따위로 해석하기 난해하면, 수학적인 방법으로는 제어규칙(Control Rule)을 찾기 어려운 경우가 많다. 그러나 J. C. Maxell의 제어시스템 안정성 이론보다 J. Watt의 Flyball Governor제어기가 100년 먼저 발명되었듯이, 인간은, 가끔 영리하게, 실질적으로 잘 동작하는 훌륭한 자동 제어 방법을 찾아 내곤 한다. 우리는 이런 형태의 제어 방법을 (그 원리가 수학적으로 엄밀하게 설명되기 전까지) <지능제어>라 부르기도 한다. 이들은 기존의 수학적 기반 제어 방법과 다르면서 제어 성능이 상대적으로 뛰어나거나 간편하거나 또는 구현 비용이 저렴하다는 잇점들이 있는 방법들로서 그 활용 범위가 확산되고 있다. 특히 최근에 지능제어의 주요 응용대상으로 로봇이 부각되고 있으며, 스마트 홈(Smart Home)과 같이 복잡한 대규모 시스템의 제어에도 도입되고 있다.

원래, 1970년경 K. S. Fu가 당시 한창 주목을 받던 인공지능(AI) 기법을 자동제어(AC)와 결합한다면 무인항공제어 비행이 가능할 것이라면서, 지능제어(IC=AI+AC)라는 말을 언급한 것이 이 개념을 처음 소개한 문헌[1] 중 하나로 꼽힌다. 그 후 지능제어란 이름으로 여러 종류의 방법론/알고리즘들이 발표되었는데, 대체로, 사회발전과 함께 자동화에 대한 요구 또는 활용 범위가 단순한 물리-화학적 플랜트를 뛰어 넘어 환경, 경영, 사회적 시스템으로 확대되면서 지능적 기법의 사용 범위가 날로 커지고 있으며, 현재까지도 여러 가지 다양한 방법들이 지능제어라는 명칭으로 소개되고 있다. <지능제어>에 관한 핸드북도 오래 전에 발간된 바 있다[2]. 사람의 손이 많이 가는 생산현장, 가정환경 또는 로봇과 인간이 상호작용하는 휴먼-인-더-루프 시스템(Human-in-the-loop system)이 자동화를 위한 응용 대상의 좋은 예들이다. 이 경우, 지능제

어기는 부정확성 또는 불확실성에 대한 융통성 있는 판단력과 예상치 못한 돌발사태에 대한 독창적 대처능력을 보유한 “인간 제어기”(Human Controller)를 대체하는 역할을 한다(그림 1).

<지능제어(IC)>도 <최적제어>와 마찬가지로 제어의 한 방법이다. 그런데 <최적제어>는 대학 교과목으로서 교재가 있고 세계 어디서나 그 과목 내용이 유사한 반면에, IC에 관하여는 강의 내용이 아직 통일되어 있지 못하고 학교에 따라 다른 경우를 본다. “지능제어(IC)라는 단어를 핵심 주제로 하여 제출한 연구제안서가 승인되어 연구비를 받은 사람은 IC 분야 연구자라 주장할 수 있다”-고 쓴 S. Yukovici (IEEE CS Magazine 1994)의 해학적 코멘트 후, 20년 지났어도 아직 “무엇이 지능 제어인가?”라는 물음에 대하여 교과서적으로 쉽게 답을 찾을 수 없다. 이에 본 조사는 논문에서는, 먼저, <지능제어>의 정체성을 알아보기 위한 노력의 일환으로, 그 동안 제안되어 온 여러 지능제어기법들의 다양성을 고찰해 보고, 다음, 지능제어기법 중 실용적으로 큰 효과를 보이는 기술들 중의

그림 1. 인기 있는 지능제어의 예.

Fig. 1. Example of popular intelligent control.

* Corresponding Author

Manuscript received January 24, 2014 / accepted February 3, 2014

변증남: KAIST 전기 및 전자공학부 명예교수, 울산과학기술대학교 전기전자컴퓨터공학부 석좌교수(zbien@unist.ac.kr)

서일홍: 한양대학교 서울캠퍼스 공과대학 융합전자공학부 (ihshuh@hanyang.ac.kr)

하나인 퍼지기반제어기술과 아직 실체가 뚜렷하지 않은 미래형 지능제어기법으로서 학습제어기술, 그리고 최근 로봇분야에서 큰 관심을 끌고 있는 인지제어기법에 대하여 중점적으로 기술하기로 한다.

본 조사 논문(article)이 갖는 한계를 미리 밝히는 의미에서 조사대상 범위에 대하여 미리 언급하자면, 본 논문에서는 <지능제어기> 자체를 중점적으로 다룬다는 점이다. 지능의 개념이 제어시스템 전체에 융합된 경우나 지능제어기가 장착된 시스템이거나 모두 지능(제어)시스템 이라고 부르지만, 지능시스템이라 해서 그 제어기가 지능적일 필요는 없다는 점 때문이다. 예컨대, 로봇의 경우, 전체 제어시스템이 제어대상, 센싱부, 제어부, 액션부로 구성된다면, PD-type제어부를 채택한 로봇도 센싱부나 액션부가 지능적이면 지능로봇이라 부른다.

II. 지능제어-개념의 다양성

지능제어(IC: Intelligent Control)는 보편적이면서도 전문적으로 통용/이해되는 정의를 찾기 쉽지 않다. 물론 Wikipedia나 과학기술 용어집과 같은 사전에 보면, AI 기법을 활용한 제어기를 통칭한다든지, 인간의 지능을 흉내낸 기법이라고 설명한다. 그러나 조금 면밀히 들여다보면, 지능제어라는 용어의 의미나 역할이 다양하여 간명하게 한 문장에 담기가 어렵다는 사실을 알 수 있다.

지능이란 개념의 속성(attribute)은 성질(character)로서 이해될 수도 있고, 또는 도구(tool)로서도 이해될 수 있다. 실제로 IC기법이라는 이름으로 소개된 여러 논문들을 검토해보면 이들을 각각 다음의 두 가지 카테고리 중 하나의 색채를 중점적으로 띠고 있음을 알 수 있다.

- 1) 실체론자적 입장(Noumenalist's Position): 지능의 본질/실체를 따져 정하여 그런 성질을 갖도록 제어기를 설계하는 입장
- 2) 현상론자적 입장(Phenomenologist's Position): 생명체로부터 발견되는 스마트한 기능적 현상을 동정(identify)하고 이를 도구로 혹은 방법으로 활용하는 입장

영국 Bristol 대학의 실험심리학 교수 R. Gregory는 지능의 이런 양면성을 Kinetic Intelligence와 Potential Intelligence로 명명하였으며, 지능제어분야에 선구자적 논문을 여럿 쓴 K. M. Passino는 이 두 가지 입장을 1) 지능중심(Focus on Intelligence) 2) 방법중심(Focus on Methodology)이라 일컬었다[3]. (Passino는 자율성을 증대/확보하는 기능에 초점(Focus on Enhancement of autonomy)을 두는 제어개념을 하나의 독립적 지능제어 카테고리라 언급하였으나 그러나 “자율로봇” (Autonomous Robot) [4]이라는 용어에서와 같이, 자율성은 시스템 전체를 기술할 때, 보다 더 유효한 개념으로 보인다. Antsaklis도, 자율성 (autonomy)은 시스템이 구현하고자 하는 목적(objective)이라 볼 수 있으며, 지능제어는 여러 가지 중 한 방법일 수 있을 뿐 필요요소는 아니라는 의견을 피력하였다[5].)

이제, 각각의 카테고리에 대하여 좀 더 자세히 알아보기로 한다.

1. 실체론자적 입장(Noumenalist's Position)

3 level intelligent control architecture

그림 2. Saridis의 지능제어구조[6].

Fig. 2. Structure of intelligent control proposed by saridis.

지능제어기는 “지능을 갖는 제어기(controller with intelligence)이다”는 명칭 직역자(Literalist)적 입장이다. 이 경우는 제어에 적합한 “지능”의 실체가 무엇이나는 실체론자(noumenalist)적 질문 자체가 이슈가 된다. 많이 알려진 대로, <지능>은 응용 학문 분야에 따라 서로 관점이 다른 정의가 존재하며, 이 입장은 이용자 형편에 알맞은 정의를 사용할 수 있다는 주장이 함의되어 있다.

이 논문에서는 오래 전부터 대표적으로 다루어져 왔으며, 폭 넓은 공학적 제어시스템에 적용가능한 Saridis의 지능제어 시스템을 한 예로 소개 한다.

Saridis [6]는 먼저 <지능>이라는 개념을, 공학적 시스템에 관계되는 <기계지능>에 국한하여 제한적으로 정의하고, 그 다음, 실용적 관점에서 기계지능을 갖는 계층적 지능 제어기(hierarchical intelligent controller)의 구조를 제안하였다. 그는 “데이터를 해석하고 체계화하여, 이를 기계지식으로 변환하는 과정”을 기계지능이라 정의하였는데, 이 정의에 포함된 <기계지식>은 주어진 작업(task)을 수행할 때 발생/인식하는 무지와 불확실성을 제거하기 위하여 생성된 구조화된 정보라 하였다. 이 제안은 공장자동화와 같은 대규모 시스템의 운영에 효과적인 지능제어 방법론을 제시한 것으로서 제어기의 한 전형적인 예를 그림 2에 보이고 있다. 흥미로운 것은 소위 IIDP (Increasing Intelligence Decreasing Precision) 원칙(Principle)이 이 구조에 내재되어 있다는 점과, K. Fu의 초기

그림 3. Saridis의 지능제어 요소기술[6].

Fig. 3. Elementary techniques of intelligent control by saridis.

개념보다 발전하여, 지능제어에 관련된 요소기술들을 AC와 AI 그리고 OR(operations research)등에서 빌려 올 수 있다는 그의 관점(IC=AC+AI+OR)이다(그림 3).

현재, “기계지능(Machine Intelligence)”은 그 자체로서 활발히 연구/활용되고 있으며, 그 개념과 관련하여 한 때 기계지능지수(MIQ)에 대한 연구도 여럿 있었으나[7] 실제로는 별로 활용되고 있지 못하는 것 같다. Saridis의 경우와 같이 지능의 본질을 나름대로 정의하고 이를 제어기 설계에 적용하겠다는 접근 방법은, 지능의 개념이 여러 장르에서 발현될 수 있고 이를 자연스럽게 각자의 시스템에 설득력 있게 활용할 수 있다는 장점이 있다. 개념상, swarm intelligence, market intelligence, emotional intelligence등, 많은 지능 개념이 존재하며, 각각을 시스템 목적에 맞게 적절히 활용될 수 있을 것이 다[8]. 반면에 그 개념을 정의하는 관점이 실용적일수록 활용 범위가 제한되어 보편성을 갖기가 어려울 것이란 단점이 있어 보인다.

2. 현상론자적 입장(Phenomenologist Position)

지능이 무엇인가-를 일목요연하게 압축적으로 기술하기는 어려워도, 우리는 지능이 있는 것과 없는 것, 또는 A가 B보다 더 지능적이다-라는 식으로 “지능적인 현상(phenomenon)”에 대하여 쉽게 이해/표현한다. 이런 관점에서, ‘인간을 포함하는 어떤 생명체가 유익/유효한 제어 행위를 하는 것’을 모방하여, 이와 유사한 작용을 재현할 수 있는 제어기를 지능 제어기라 정의하려는 것이 두 번째의 입장이다. 즉, 이 입장에서는 먼저, 보편/선험적으로 인식되는 지능적인 존재(Intelligent being)를 상정하고 이들이 행하는 제어방법을 흉내내는 것인데, 이때 모방하는 속성(attributes)들이 다양하고 여러 가지가 있다. 학습, 적응성, 불확실성 다루기(uncertainty handling) 등, 많이 언급되는 항목들의 리스트를 부록 A (지능적 행동의 속성 리스트)에 수록하였다. 속성이 단순한 것부터 매우 복잡한 것까지 다양하며, 제어기술이 하나 또는 그 이상의 속성을 성능으로 가지고 있을 때, 그것을 지능적 제어기술이라 부르겠다는 것이다.

Zadeh는 인간이 고안해 낸 기술들 중, “불확실하거나 부정확하거나 또는 부분적 진리값을 갖는 명제들을 추론하고 학습하는, ‘인간의 놀라운 정신작용’에 버금가는 계산기술들을 총칭하여 소프트계산기술(Soft Computing Techniques)이라 하였다. 이런 새로운 기술은 부정확성, 불확실성, 또는 부분적 진리값을 갖는 명제의 오차허용도(tolerance)를 역으로 활용하여 다루기 쉽고, 강인하고 저렴한 비용의 해(solution)를 구할 때 곧 잘 활용된다. 소프트컴퓨팅기술을 계산지능기술(Techniques of Computational Intelligence)이라 부르기도 하며, 이 기술과 기준에 우리가 쓰고 있는 컴퓨팅기술, 즉, 이진 논리체계하에 엄밀성과 정확성을 무기로 하는 von Neumann식 계산법을 하드컴퓨팅(Hard Computing)이라 하여 대조한 표가 그림 4에 있다[9].

소프트계산기술(SCT)로서, 대표적으로 퍼지(FUZZY = Fuzzy set and logic)기술과 인공신경망기술(ANN), 그리고 유전자알고리즘(GA) 등이 제어기 구현에 주로 많이 이용되고 있다. 이외에도 SVM, HMM, Rough set Theory등도 요소기술/도구로서 포함하여 하나의 집합(box)을 만든 후, 설계과정에 필요한

Soft Computing vs. Hard Computing

그림 4. 소프트컴퓨팅 대 하드컴퓨팅.

Fig. 4. Soft computing vs hard computing.

기술도구를 융합적으로 활용하여 소기의 목적을 달성하도록 하는 도구상자접근법(toolbox approach)을 쓸 수 있다는 것이 이 입장의 강점이다. 대학 강의 교재용으로 “Intelligent Control”-이라는 제목의 단행본이 여럿 있는데, 많은 경우 FUZZY와 ANN을 주로 다루고 어떤 책은 FUZZY만을 다룬 책들도 있다[10,11].

III. 퍼지-기반제어 (FUZZY-based Control)

제어공학적 입장에서 봤을 때, 인간이 기계(컴퓨터)와 다르면서 뚜렷이 우월한 것은 애매성/불확실성에 대한 판단과 액션이 유연하다(flexible)는 데 있다는 것일 것이다. 프로그램을 하다가 보면, 수 천 개의 글자 중에 한 글자만 잘못 입력을 해도 프로그램이 돌지 못하는 컴퓨터에 비해, 사람이라면 조금 에러가 있더라도 그 에러가 어떤 종류인지를 판단하고, 많은 경우 상황에 맞는 적절한 결과를 낸다. 그런데 퍼지 논리를 쓰면, 어느 정도는 기계도 인간처럼 유연한 판단을 하게 할 수 있다. 예를 들어, “If $x=A$, then $y=B$.” 라는 명제가 주어졌을 때, 입력으로 $x=A$ 대신, 조금 다른 입력인 $x=A'$ 입력했을 경우, 출력 y 는 무엇이 될 것인가-하는 문제에 대하여, 기계도 A 와 A' 가 비슷하면 출력으로 $y=B$ 와 엇비슷한 $y=B'$ 값을 도출하는 근사추론(Approximate Reasoning)이 가능하도록 설계할 수 있다[12].

또 한가지는 인간의 언어가 기계적 언어보다 다양하고 고차원적이며 단어 하나에도 여러 복합적인 의미를 담을 수 있다는 것이다. 그것은 대규모 데이터의 핵심을 축약하여 감성이 담긴 언어로 나타낼 수 있는 인간의 특별한 기능 때문인데, 그런 인간의 언어에 퍼지 집합이론을 활용하면, 여러 종류의 언어 변수 값(예: Hot (temperature) of a bathtub)을 구간 값(interval)대신 소속 정도(membership)를 갖는 퍼지집합으로 표현할 수 있다. 다시 말해, 기계와 인간이 서로 다른 많은 점 중에서 적어도 이 두 가지 속성들에 대하여, 퍼지이론(fuzzy set and logic) 체계가 그 간격을 좁히는 역할을 할 수 있으며, 이 내용을 좀 더 구체적으로 간단히 살펴보기로 한다.

먼저 퍼지집합은 그림 5(a)에 보인 대로 경계가 불분명한 집합을 지칭하며, 소속의 정도를 나타내는 소속함수를 그림 5(b)에 보였다.

수학적으로는 X (Universe of Discourse)라는 정의역(domain) 집합에 대하여, 먼저, 소속함수

그림 5. 경계가 애매한 퍼지 집합.

Fig. 5. Fuzzy set with ambiguous boundary.

그림 6. 근사치 $3 \approx \tilde{3}$.Fig. 6. Approximately equal to $3 \approx \tilde{3}$.

$$m_A : X \rightarrow [0,1]$$

를 정의한 후, 각 원소 x 마다 소속 정도를 갖는 집합

$$A = \{(x, m_A(x)) | x \in X\}$$

를 퍼지집합이라 정의한다. 정의역집합 X 가 1차원인 경우의 예로, ‘대략 3’이란 퍼지집합을 다음에 보았다.

이러한 표현법은 에러가 크다, 작다, 중간이다-와 같은 실험실 용어는 물론, 특히 우리가 일상 사용하는 언어들, 예컨대, 키가 크다, 작다, 중간(Medium)이다-고 하는 양을 나타낸 다든지, ‘목욕탕물 온도’라는 언어변수에 대하여 뜨겁다, 차갑다, 보통이다, 미지근하다, 또는 미적지근하다는 등, 주관적이지만 감성적 느낌을 포함하는 개념을 컴퓨터(기계, 로봇)가 이해/표현하는 데에 활용될 수 있다.

FUZZY는 1965년에 발표된 개념이다[13]. 이 개념이 여러 산업분야에서 정보처리, 클러스터링 등에 응용되고 있을 뿐 아니라 전문가시스템 같은 지식기반 응용에 특히 유용하다. 전술한 바와 같이, 휴먼-인-더-루프-시스템에서 인간을 대체하는 자동제어기를 설계/구축하는 데에 성공할 때가 많다. 인간이 경험적으로 얻어 갖고 있는 전문가적 지식/규칙을 추출하여 이를 컴퓨터가 처리할 수 있는 제어규칙으로 사용하면 된다. Mamdani가 실험실에서 스팀엔진 제어에 퍼지집합을 응용했다는 보고(1974)가 있으나, 세계적 관심을 끌게 된 것은 1980년대에 네덜란드 Smith Co.에서 수학적 모델 기반 제어 기술로는 안되었던 Cement Kiln제조공정 자동화에, 종업원들이 그 동안 사용하던 조작자 규칙모음집(operator's rule book)을 퍼지 전문가규칙으로 변환하여 사용함으로써, 전 공정자동화에 성공한 것이 계기가 되었다. 그 후, 일본에서 세탁기와 같은 가전제품들도 보다 사용자 친화적 자동제어가 가능

하다는 것이 증명됨으로써 우리나라에도 많이 알려지게 되었다[9].

1. 퍼지 제어기

퍼지제어기의 일반적 구성도는 그림 7과 같으며, 아래에 몇 가지 간단한 코멘트를 첨가하였다.

- 1) 퍼지제어기의 구성은 마치 디지털제어기가 A/D converter, D/A converter, rule set memory, computing element를 갖는 것과 유사하다.
- 2) 이 제어기의 특징은 두 가지다. 첫째 언어변수를 다룬다는 것이며, 언어로 표현되는 집합개념의 요소가 의미집합에 속하는 정도, 소속함수를 통해 우리 감성을 수학적으로 묘사하고, 둘째, 논리체계로 근사추론이 가능하다는 것이다.
- 3) 많은 테스트를 거쳐 가장 많이 쓰이는 퍼지논리규칙은 합성추론규칙(computational rule of inference: CRI)이다. 도식적으로 그림 8와 같이 나타낸다.
- 4) 잘 조정된 퍼지제어기의 퍼지 성능이 우수한 것은 이 제어기가 갖고 있는 비선형성특성에 기인한다. 한 예로, 비례미분제어기와 유사한 퍼지제어기를 구성하면, 기준값과 출력의 오차 및 오차미분을 다루는 오차벡터공간의 제어액션(control action) 집합 면이 유사 PD-퍼지제어기의 경우 그림 9와 같이 완만하지도 또는 평탄치도 않다. 퍼지제어 시스템의 경우, 에러가 작을 때는 완만하나 큰 에러에 대하여는 급격한 변화로 대응하는 특색 때문에 스텝응답이 rise time/settling time은 짧으면서 overshoot가 작은 특색을 보인다.
- 5) 흥미로운 퍼지제어기의 실현 예로서 카이스트 제어랩(BSCL)에서 개발한 요요(YoYo)장치와 다이내믹스를 그림 10에 보이고 있다. 이것은 수학적 모델이 있어도, 제어법칙(control law)을 계산하기 어려운 상황에서, 요요를 움직여 본 많은 경험을 통하여 퍼지규칙을 추출하고 이를 이용하여 성공적으로 요요가 스스로 작동되는 자동제어시스

그림 7. 퍼지제어기 구조.

Fig. 7. Structure of fuzzy controller.

$$\tilde{P} \rightarrow \boxed{\tilde{R}} \rightarrow Q = \tilde{Q} = (\tilde{P} \circ \tilde{R})$$

$$m_{\tilde{Q}}(y) = \max_x \min(m_P(x), m_R(x, y))$$

그림 8. 합성추론규칙 (CRI).

Fig. 8. Compositional rule of inference.

템을 구축하였다[14].

퍼지는 그 동안 선풍기와 같은 간단한 가전제품부터 시멘트공장, 지하철, 오버헤드크레인, 심해용 또는 터널용 굴착기, 쓰레기 소각로, 철공장 등 여러 종류의 대형시스템 자동화에 성공적으로 쓰이고 있다. 장점은 비수학적이기 때문에 안정성이 보장되는 한, 경험적 시행착오 규칙을 룰(rule)로 만들어 적용할 수 있다는 것이다.

u	NB	NM	NS	PS	PM	PB
PB	PZ	PS	PM	PM	PB	PB
PM	NS	NZ	PS	PM	PM	PB
PS	NM	NS	NZ	PS	PM	PM
NS	NB	NM	NS	NZ	PS	PM
NM	NB	NM	NM	NS	NZ	PS
NB	NB	NB	NM	NM	NS	PZ

(a) PD-like fuzzy control table.

Fig. Transfer characteristic of a FKBC.

(b) Value set of a fuzzy controller action.

그림 9. 유사비례미분 퍼지제어기.

Fig. 9. P-D-like fuzzy controller.

그림 10. Yo-yo 퍼지제어 시스템.

Fig. 10. Yo-yo fuzzy control system.

그림 11. 퍼지 모델기준 학습제어기 (FMRLC).

Fig. 11. Fuzzy model-reference learning control.

6) 현실적으로 규칙 테이블(rule table)을 형성하는 데에 실질적인 어려움이 있거나 높은 비용을 들여야 할 경우도 있어, 자동적으로 획득되는 규칙집합(rule set)을 얻으려는 노력이 있어왔다. 예컨대, 자기조직 퍼지제어기(self-organizing FLC) [15] 또는 퍼지모델기준 학습 제어시스템(Fuzzy Model Reference Learning Control) [16]이 있으나, 활용에는 제한적이다(그림 11).

7) 퍼지제어시스템 이론에 관한 한, Sugeno가 소위 Sugeno Model [17]을 이용하여 안정성 증명을 발표적이 있으나, 일반적으로 퍼지제어시스템의 안정성을 이론적으로 밝히기가 쉽지 않다[18].

2. 퍼지-기반 제어

지능제어기법 중에 인공신경망회로망(ANN)을 이용한 제어가 중요한 한 축을 이룬다. 그러나 본 논문에서는 지면상 간단히 다루고, 주로 FUZZY+ANN의 융합형 제어시스템에 대하여 소개하기로 한다.

2.1 ANN(인공신경망)과 뉴로제어기

잘 알려진 대로, 뇌에 신호 흐름 동작 행태/현상을 단순한 모델로 만들어 제안한 1943년의 Mculloch=Pitts Neuron model이 효시가 되어, 여러 굴곡을 거쳐 발전한 다층 퍼셉트론(Error back propagation-base Multilayer perceptron)이 전형적인 ANN으로 자리하고 있다(그림 12). 이것이 강력한 학습의 수단이 되는 것은 적절한 수의 뉴론을 결합하면 어떤 비선형적 함수라도 근사화할 수 있다는 범근사화정리(universal approximation theorem of nonlinear functions)가 든든히 지원하고 있기 때문이다(그림 13).

이 신경망장치를 이용하여 플랜트의 다이내믹스를 동정(identification)한다든지, 적절한 성능을 갖는 제어기로 학습시

그림 12. 다층 퍼셉트론.

Fig. 12. Multi-layer perceptron.

그림 13. ANN의 근사화기능도.

Fig. 13. ANN-based function approximation process.

* Filter : "Disturbance" Rejection

그림 14. IMC를 위한 ANN기반 제어시스템.

Fig. 14. ANN-based control system for IMC.

그림 15. 적응뉴로퍼지추론기(ANFIS)블록선도.

Fig. 15. Block diagram of adaptive neuro-fuzzy inference system.

키는 것이 가능하다. 그림 14에 ANN이 IMC(Internal Model Control)에 활용되는 예를 보이고 있다. Artificial Neural Nets의 다양한 모델이 있고, 이 ANN기반 제어기가 갖는 장단점들이 있으나 여기서는 기술을 생략한다.

2.2 뉴로퍼지제어기: 퍼지와 신경망의 결합체

여러가지 방법으로 FUZZY와 ANN을 결합할 수 있는데, 효과적으로 많이 쓰이며 간단하고 학습규칙도 명확히 잘 정의된 적응뉴로퍼지추론기(ANFIS: Adaptive Neuro-Fuzzy Inference System) [19]를 그림 15에 보이고 있다. 이 시스템의 운영 알고리즘을 각 층별로 나누어 부록 B에 수록하였다.

3. 퍼지기반제어의 전망(Out look)

퍼지기반 제어기는 그의 불확실성과 부정확성 또는 부분적 진리 값을 갖는 명제를 다루는 특성에 더하여 학습이나 최적화 기능들을 필요에 따라 융합할 수 있어, 앞으로도 지능제어기법으로 활발하게 많이 이용될 수 있을 것으로 전망된다. 특히 FUZZY와 관련하여 앞으로 주목을 받을 수 있는 가능성 항목으로 다음에 3가지를 소개한다.

(a) GA-based P-I-D tuner.

(b) Type 2 fuzzy set.

그림 16. 유전자알고리즘기반 PID 튜너와 타입2 퍼지집합.

Fig. 16. GA-based PID tuner and type 2 fuzzy set.

3.1 SCT 도구상자접근법의 모범적인 요소 기술

FUZZY는 여러 복잡한 시스템의 지능제어를 구현하는데 있어, GA, Rough Set 등, 손쉽게 다른 기술과 결합하여, 효과적인 제어를 하는데 쓰일 수 있다[20,21]. 그림 16(a)에 GA (Genetic Algorithm)를 써서 종래의 PID제어기를 조정하는 예를 보여준다.

3.2 Type-2 퍼지집합과 응용

요즈음 퍼지 커뮤니티에서는 Type II Fuzzy Set에 많이 주목하고 있다(그림 16(b)).

Type-2 퍼지집합은 원소 x의 소속 값이 수(數)가 아닌 퍼지 집합으로 표현되는 경우로서, 소속함수가 다음처럼 이중으로 표현된다.

$$\mu_2(x, \mu_1) = e^{-\frac{1}{2} \left(\frac{\mu_1 - m(x)}{\sigma} \right)^2}$$

$$m(x) = e^{-\frac{1}{2} \left(\frac{x - m(x)}{\sigma} \right)^2}$$

이 퍼지집합은 소속정도를 정하는 데에 내재하는 불확성을 보다 유연하게 모델링하고자 할 때 활용될 수 있다. 금융계/시장시스템 제어 문제에 활용될 수 있을 것으로 보인다 [22].

3.3 Smarandache's Neutrosophic Logic의 등장

주목되는 것은 퍼지논리를 확장한 새로운 논리 체계로서 Smarandache's Neutrosophic Logic이 제안되었다는 사실이다. 퍼지를 포함한 기존의 논리로 쉽게 다룰 수 없는 갈등현상(conflict)이나 딜렘마(dilemma) 등도 논리연산처리가 가능한 체계로 보이며, 앞으로 “시스템들의 시스템(system of systems)”과 같은, 현실적 공학적 시스템 이상의 복잡한 계(complex world)의 제어개념에 활용될 수 있을지 주목된다.

IV. 학습 제어

제어공학 문헌에, 학습(Learning)이란 용어가 지능(Intelligence)이란 말처럼 많이 회자되고 있으나 이 역시, 기존의 잘 확립된 제어방법과 연계할 때는 <학습>의 실제(정체)가 애매해진다. 계산과학관점에서, 학습을 “순차적으로 제공되는 예(examples)에 기반하여 진행되는 자동화시스템 최적화 과정”이라고 정의(M. Sonica)하는 등, 공학기술서적 여기 저기에 학습에 대한 정의가 많이 있다. 학습의 종류도 다양하여, 로봇틱스 분야에서는 학습방법을 교시(敎示)/비교시 학습(supervised /unsupervised learning)으로 구분하여 다루며, Meystel과 J. S. Albus는 학습의 타입(type)으로 부록C에 보인 바와 같이 20가지 종류를 열거하였다[23]. 이런 학습의 개념이 제어시스템과 연관되어 언급된 것은 “지능”보다 다소 먼저인 듯하다. Tsypkin이, 심리학에서 사용하던 학습의 개념을 원용하여, 학습제어(learning control)란 용어를 1966년경 사용한 것이, 초기에 등장한 예라 볼 수 있다[24].

초기에는, <학습제어>라는 용어를, 구조가 잘 파악되지 않은 플랜트에 특정 입력을 가하여 원하는 출력이 나오도록 교정하는 기능을 갖는 제어시스템의 의미로 사용하였으며, 그 후 많은 사람들이 학습기능이 있는 제어기에 대한 구조를 제안하고 가능성에 대하여 언급하였다. 앞에서 언급한 바와 같이 ANN의 학습기능을 이용한 <ANN-기반 학습제어기>가 실용적으로 쓰이고 있으며, 이미 하나의 중요한 학습제어기의 역할을 담당하고 있다. 최근에는 인간의 학습기능을 뇌신경-심리학 측면에서 이해하려는 연구가 활발해지면서 인간의 학습원리를 공학적 학습시스템에 적용하는 연구결과도 발표되고 있다[25].

여기서 학습의 개념이 제어시스템과 관련하여 어떻게 활용되고 있는지 간단히 검토해 보기로 한다.

문헌에 나와 있는 학습알고리즘/학습방법들을 보면 그 대체적인 기본 틀은 다음과 같은 식으로 표현된다:

$$W_{new} = W_{old} + \Delta W$$

$$NewEstimate = OldEstimate (OE) + StepSize [Target - OE]$$

예컨데, ANN의 BP 알고리즘에서 뉴런의 weight 갱신(update) 조건은

$$\Delta w = -\eta \frac{\partial E}{\partial w}$$

이며, 강화학습에 쓰이는 Q-Learning 알고리즘도 다음 식과 같이 이런 형태이다.

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [r_{t+1} + \eta \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t)]$$

이와 같이, 학습이라는 개념이 일종의 최적화 목표를 향한 조정/갱신과정으로 쓰이고 있음을 자주 보는데, 우리가 통상적으로 사용하는 “학습”의 개념에는 좀 더 고차원적인 기능도 포함될 수 있다는 생각이 든다. 실제로, Antsaklis는 <지능 학습제어(intelligent learning control)>라는 IEEE 제어시스템 잡지 1995년도 특집 기고문[26]에서, 전통적인 학습알고리즘에 “기억하는 작용(remembering)”을 추가하는 것이 <학습>이라는 개념 자체에 더 가깝다고 주장하였다. 과거에는 학습한다는 것을 적응(adaptation), 튜닝(tuning) 또는 갱신(updating) 작업과 같이, 함수의 미지수를 찾기 위한 일련의 근사화 과정(successive approximation)으로 이해되었다면, 우리는 이런 단순한 적응/튜닝/갱신 개념에 더하여, <과거에 행한 적응/튜닝/갱신 작용의 기억함(remembering)>을 통하여 보다 효율적으로 목표를 달성하는 것을 학습의 본질적인 기능으로 본 것이다(Learning=Adapting/Tuning + Remembering). 또는, 간단히, “튜닝을 튜닝하는 것”(Tuning of Tuning: 2nd order tuning)을 학습이라고 볼 수도 있다. 이런 관점에서, 기존의 단순한 갱신작용의 학습규칙에 더하여 학습과정의 패턴을 스스로 관찰하며 효과적인 학습을 할 수 있는, 외란에 강인한 새로운 학습 패턴다임을 보유한 자기조직 퍼지제어기 설계 예를 [27]에서 볼 수 있다.

좀 다른 관점에서 G. Saridis는 학습제어시스템을 “학습자(Learner)”라는 특정한 장치를 갖는 시스템으로 정의하였으며, 필요한 학습자의 기능을 부록 C 리스트에 보인 바와 같이 제안하였다. 또 다른 블록다이어그램 차원의 예로서, 제어기에 학습개념이 도입된 학습제어 시스템의 예제를 그림 17에 보였다[23].

<학습제어>는 앞으로 대규모이면서 대형 데이터를 다루는 시스템의 운영에 필수불가결한 개념으로 생각된다. 예컨데, 스마트홈/스마트타운과 같이 복수의 로봇이 여러 대상과 여러 사람 사이에 여러 종류의 상호작용을 하면서 제어행위가 형성되는 환경에서는, 특히, 장기간 지속되는 제어시스템 환경을 구축하는 과업이 요구되며, 이는 아주 어려운(challenging) 문제로 생각된다. 많은 경우, 큰 단위의 시간(오전/오후, 일, 월, 계절)이 바뀌면서 또는 인간이 기분 따라 선호하는 작업결과가 바뀔 수 있다는 측면에서 개인화

그림 17. 학습제어시스템[23].

Fig. 17. Learning control system.

그림 18. 장기 퍼지 학습 시스템[29].

Fig. 18. Fuzzy life-long learning system.

그림 19. 반복학습제어 시스템 블록선도.

Fig. 19. Block diagram of iterative learning control system.

(personalization)이슈 등 상당히 성공률이 높은 학습 프로그램을 갖는 제어시스템이 요구된다. 일례로 전향적인 서비스를 하도록 할 때, 경험 많은 집사처럼, 로봇은 사람의 감정을 읽어 주인의 입맛에 맞는 서비스를 할 수 있다. 이런 인간친화적 환경에 쓰일 수 있도록, 장기 학습 제어(Long-term Learning-Control)시스템에 대한 연구가 필요하며, 그림 18에 보인 바와 같이 여러 종류의 학습알고리즘을 내장하는 장기 학습시스템 구조에 대한 연구가 시작된 것은 반가운 일이다 [28,29].

지금까지 소개한 바와 같이, 대부분의 <학습제어> 논의가 개념적 구조를 제안하는 정도의 차원이라 할 수 있는데, 다소 단순하지만, 분명한 제어기 구조를 갖고 있으며 이론적으로 수렴성 증명이 가능한 학습방법이 있다. 그것은 반복학습 제어(ILC: Iterative Learning Control) 방법[30]으로서, 모델이 불확실한 시스템에 대하여 반복적 시행착오 학습을 통해 원하는 출력궤적(output trajectory)을 찾아가는 학습제어방법이다 (그림 19).

좀 더 구체적으로 설명하자면, 이 학습제어는 플랜트의 모델에 대한 구체적 정보가 없는 환경에서 출력궤적이 주어진 원하는 출력궤적과 같아질 때까지 다음과 같은 형태의 제어값을 순차적으로 반복해서 입력하는 것이다.

$$u_{k+1}(t) = u_k(t) + \Gamma_p e_k(t) + \Gamma_I \int_0^t e_k(\sigma) d\sigma + \Gamma_d \dot{e}_k(t)$$

그러면 다음과 같이 Function-target control 이 완성되는 것을 이론적으로 증명(convergence proof)할 수 있다.

$$\lim_{k \rightarrow \infty} y_k(t) = y_d(t)$$

이 반복학습제어 알고리즘의 구조는 아래와 같다.

반복학습제어(ILC)에도 여러 형태[31,32]가 있는데, 과거와 그 이전 정보를 동시에 이용하는 2nd order ILC 알고리즘이 다음과 같이 고안되었다[33]:

$$u_{k+1}(t) = P_1 u_k(t) + P_2 u_{k-1}(t) + Q_1 e_k(t) + Q_2 e_{k-1}(t)$$

그림 20. ILC 알고리즘 구조.

Fig. 20. Structure of ILC algorithm.

(a) 2nd Order ILC. (b) 1st Order ILC.

그림 21. ILC적용에 의한 출력궤적 수렴.

Fig. 21. Convergence of output trajectory due to application of ILC.

이 방법으로 기존의 결과보다 목적하는 출력이 더 효과적으로 빨리 학습되고 수렴됨을 그림 21에 보였다. 이 ILC는 산업용로봇이 페인팅작업과 같은 과업을 진행하도록 하는데 응용될 수 있다. 향후 이러한 방법론을 발전시켜, 다른 학습 제어 방법에도 보다 구체적 알고리즘과 이론적 지원(backup)이 가능하도록 구현할 일이 기대된다.

V. 인지 제어

제어공학자 관점에서 본 지능제어 방법들은 제어 시스템이 실제 지능을 가지고 있는지 (얼마만큼 지능적인 동작을 보이는지)가 목적이 아니라, 주어진 제어 문제를 푸는데 있어서 얼마나 나은 성능을 가지고 있는지가 목적인 경우가 많다. 이 과정에서 어느 정도의 자율성이 제어기에 필요로 하게 되는데, 사양을 만족하기 위한 파라미터들의 조정을 자율적으로 결정하는 것 등이 예가 될 수 있다. 하지만, 인간이나 생명체가 보이는 수준의 높은 자율성을 갖는 시스템을 위해

서는 주어진 사양에 맞도록 기준 신호를 시스템이 따라가도록 하는 제어에 대해서, 시스템이 처한 상황을 인지하고, 상황에 맞는 기준 신호를 인간의 개입 없이 생성할 수 있는 방법이 요구된다. 본 글에서는 이에 대한 대안의 하나로써 인지 제어를 소개하고자 한다.

왜 인지제어가 필요하지 살펴보기에 앞서 인지기능을 진화 관점에서 살펴보고자 하겠다. 생명체는 다윈니안(Darwinian), 스키너리안(Skinnerian), 포퍼리안(Popperian), 그리고 그레고리안(Gregorian) 생명체로 진화해 왔다[34]. 이들 네 가지 생명체는 진화시간의 축 상에서 순서대로 출현되었으며 단순한 구조에서 점점 복잡한 구조로 진화하다가 마지막 단계에서 그레고리안 생명체인 인간에 이르게 되었다. 다윈니안 생명체는 외부의 특정 신호입력에 가장 잘 반응할 수 있도록 고정된 행위체계를 수립함으로써 자신의 종이 잘 보존해 나가기 위한 행위기반의 지능으로 해석할 수 있다[35]. 스키너리안 생명체는 자극과 반응의 관계에 대한 학습을 통해 적응적으로 자신의 종을 보존해 나가는 강화학습 기반의 지능으로 해석할 수 있다. 포퍼리안 생명체(침팬치류 등)는 지각된 정보가 시각인 경우에는 이미지의 특징들을 기억함으로써 환경을 모델링하고 기억하는 특징이 있다. 이미지를 기반으로 하기 때문에 많은 양의 정보를 기억하거나 처리하는데 어려움이 있다. 한편, 이들 포퍼리안 생명체는 앞선 두 생명체와 달리 개체 중심이 아닌 집단행동을 통해 행위의 효과를 최대화할 수 있는 사회적 인지기능을 보여준다. 마지막으로 그레고리안 생명체는 언어를 통해 심볼을 기반으로 환경에 대한 모델링을 하며, 이들 심볼과 관련된 여러 지식 체계를 구축하고, 매우 복잡한 형태의 정보를 용이하게 처리할 수 있다. 그리고 이를 통해 추론과 예측을 할 수 있게 되었으며, 서로 다른 그레고리안 생명체들과 언어를 통해 교류한다. 다시 말하면, 그레고리안 생명체의 주요한 특징은 지각된 정보로부터 주요한 패턴을 추출하고, 이를 심볼과 연결시켜서 환경을 학습하고, 이를 기반으로 앞으로 어떤 일이 발생하는지를 예측하는 뛰어난 능력이 이 생명체의 큰 특징으로 볼 수 있다. 그레고리안 생명체는 다윈니안부터 포퍼리안 생명체가 갖고 있는 모든 특징도 포함하고 있다. 그러므로, 그레고리안의 지능은 앞서 설명한 네 종류의 인지특성들이 포섭구조를 이루고 있어야 한다.

인지 제어를 위해서는 그림 22와 같이 이러한 네 가지 생명체가 갖는 특징을 모두 포함하고 있는 하나의 프레임워크가 필요하다. 기존의 제어는 앞서 설명한 네 가지 생명체의 주요한 특징인 학습보다는 환경의 모델이 주어졌을 때 가장 환경에 맞게 움직임을 생성하는 것을 주 역할로 볼 수 있다. 따라서, 무인 항공기와 같은 현대 제어 시스템에서 입증된 것처럼 매우 잘 정의된 환경과 시스템하에서 동작하도록 해야만 한다.

그러나 이들 제어 시스템들은 제어기를 디자인하는 단계에서 고려되지 않은 새롭고 예측 불가능한 상황에 직면하였을 경우 본질적으로 인간의 개입을 필요로 한다. 그런 상황들은 환경의 비연속적 변화, 극단적인 방해, 시스템의 구조적 변화 등 다양한 원인들에 의해 발생할 수 있다. 예를 들어, 탐사, 채광, 서비스, 자동 운전과 같은 미래의 자동화 로봇들

그림 22. 다윈니안, 스키너리안, 포퍼리안, 그리고 그레고리안 생명체들의 인지 특성 및 인지 제어를 위한 각 인지 특성들의 포섭구조[34].

Fig. 22. Cognitive functions included in Darwinian, Skinnerian, Popperian, and Gregorian creatures and their subsumption architecture for developing a cognitive control.

은 본질적으로 스키너리안부터 그레고리안 생명체가 갖는 인지 기능들인 인지, 추론, 의사 결정, 일반화, 그리고 학습이 필요한 새로운 상황들에 직면하게 될 것이다. 인지 제어는 이러한 미래의 자동화 시스템에 커다란 영향을 미치면서 동시에 “자동화”를 다음 단계로 진보시킬 중요한 역할을 하게 될 것이다[36].

한편, 인간-머신 인터페이스 개념은 인지 제어를 위한 또 다른 중요한 요소 중 하나이다. 포퍼리안부터 그레고리안의 고등 생명체가 갖는 중요한 특징 중에 하나인 사회적이고 그룹화된 환경에서의 제어: 다수의 에이전트들의 조정 및 제어, 복잡한 임무의 공동 수행, 경쟁-공존 상황들이 혼합된 상황에서 효율적인 조작을 위한 에이전트들을 필요로 하게 될 것이다. 이런 관점에서 소통은 중요하면서 복잡성을 더하게 될 것이다. 에이전트들은 언어적 소양을 필요로 할 것이고, 더욱이 의미론적 모델과 온톨로지들의 공유를 필요로 하게 될 것이다[37]. 최종적으로 의미론을 넘어 말하기나 글쓰기와 같이 언어를 사용하여 의사를 전달하는 과정에서 인간이 직접적으로 관련되지 않은 의미를 파악하는 것처럼 인지 제어 시스템들도 그렇게 하게 될 것이며, 사물-인터넷(internet of things)이 주요한 역할을 할 것이다[38].

1. 인지 제어란 무엇인가?

인지 제어에 대한 정의를 내리기 위해서는 먼저 인지 혹은 인지 시스템에 대한 명확한 정의를 내리는 것이 필요한데 이는 논쟁의 여지가 있다. FP6 프로젝트중 하나인 “euCognition” 프로젝트에서 조사한 인지 혹은 인지 시스템에 대한 정의는 40개 이상이다. 따라서 정의를 내리는 것보다는 인지적 제어의 특성 및 구성요소에 대해 기술하는 것이 논쟁의 여지를 줄이는 효과적인 방법으로 볼 수 있다. 인지 제어에 기반한 시스템은 다음과 같은 특성을 가지고 있어야 한다[39].

- 지각, 추론 그리고 행동에 있어서 목표 지향적이어야 함.
- 목표와 행동이 상황, 맥락 그리고 경험에 따라서 변경 가능해야 함.

그림 23. 인지 제어 블록 다이어그램.

Fig. 23. Block diagram of cognitive control.

- 제한이 가해지지 않은 환경에서 사용자의 도움 없이 돌발적 상황에 적절히 대응해서 반응할 수 있어야 함.

- 사용자 혹은 다른 인지 시스템과 협업하여 복잡한 작업을 수행할 수 있어야 함.

이와 같은 특성을 가지려면 인지 제어 시스템은 다음과 같은 구성 요소를 가지고 있어야 한다.

- 현재 상황에 대한 이해가 학습과 추론을 통하여 이루어져야 함. 이 때 다른 시스템 및 에이전트에 대한 이해도 요구됨. 이를 위해서 여러 가지 기능들이 필요한데 예를 들자면 능동적 지각, 관련된 지식의 검출과 추상화, 시멘틱 지식의 획득, 과거의 경험과의 비교, 지식의 업데이트 등임.

- 목적지향적으로 행동하여 현재의 상황을 바꾸고 예측하지 못했던 상황에 대해서 적절히 대응해야 함. 이를 위해 의사결정, 계획, 추론, 학습, 적응적 행동 등이 필요함.

중요한 점은 인지 제어 시스템이 가질 수 있는 정보는 대부분 제한적인 경우가 많다는 것이다. 따라서 현재의 상태에 대해서 판단하거나 수정하는 것이 부분적이고 불확실성이 있는 정보로부터 이루어져야 하는 어려움이 있다.

그림 23(a)는 전통적인 제어 구조를 나타내고 그림 23(b)는

인지 제어 구조를 나타내고 있다. 인지 제어 시스템은 아래와 같은 단위 블록으로 구성되어 있다.

- 지식 혹은 경험(Knowledge)은 인지 제어 시스템의 기본적인 특성임. 이런 지식은 계속적으로 업데이트 되고 변화됨. 한편, 이러한 지식을 어떻게 표현하는 것이 효과적인 가는 중요한 이슈임.

- 학습(Learning)은 기존의 지식을 업데이트 하기 위해 필수적임. 불확실하고 불완전한 정보 하에서의 학습, 계층적 학습, 시간적 순서 및 관계학습 등은 이 영역에서 도전적 과제임.

- 플래닝 및 실행(Planning and execution)은 제어기의 장기적인 목표를 달성하기 위한 일련의 제어 신호를 상황에 맞게 생성하는 과정임.

- 인식(Perception)은 저수준의 센서 데이터와 다른 종류의 센서정보의 결합, 정보의 추상화, 의사결정을 위한 정보의 해석을 포함함. 문제는 어떻게 작업과 관련된 정보를 방대하게 많은 불확실하고 불완전한 데이터로부터 가려낼 수 있는 것임 (최근 들어 빅데이터가 관심을 받고 있음)[41].

2. 인지 제어를 위한 학습 방법

인지 제어를 위한 인지 기능들을 획득하기 위해서는 학습이 반드시 필요하다. 그림 24는 인지 제어를 위한 인지 기능을 학습할 수 있는 하나의 간략한 다이어그램이다. 인지 제어 시스템은 그림 24의 인지 기능 학습 과정을 통해 주변 상황에 맞는 기준 행동 계획 및 경로를 제공받을 수 있게 된다. 본 장에서는 그러한 인지 기능 학습이 가능하도록 하는 방법들 중에서 최근 많은 주목을 받고 있는 확률기반, 인공신경망기반, 강화학습기반 접근 방법에 대해 간략히 소개한다.

2.1 확률기반 접근방법

인지 제어를 위한 인지 기능을 학습하고, 모델링하는데 있어서 가장 일반적인 방법은 확률 모델을 이용하는 것이다 [42]. 일반적으로 하나의 목표를 완수하기 위해 다양한 행동

그림 24. 인지 제어를 위한 인지 기능 학습에 대한 개념 다이어그램. 3장에서 본 그림에서 학습 시스템 (learning system)에 해당하는 인지 제어를 위한 학습 방법의 대표적인 예를 살펴본다. 본 그림은 Schaal 등이 제안한 모방 학습의 개념 다이어그램을 수정 및 확장한 것이다[42].

Fig. 24. Conceptual diagram of several cognitive functions for developing a cognitive control. In Section 3, an exemplar learning system will be described to show how concepts in this figure can be developed for a cognitive control. This figure is an extended version of the imitation paradigm proposed by S. Schaal [42].

그림 25. 왼쪽의 그림은 조작자가 운동학 기반 학습 방법을 통해 로봇을 직접 잡고 학습하는 모습. 가운데 그림은 모방을 통한 로봇의 손끝 데이터를 가우시안 혼합 모델을 이용하여 학습한 결과, 여기서 x축은 시간을 의미하고, y축은 손끝 움직임을 주성분분석법에 의해 변환시킨 공간에서 표현된 정보를 의미함. 오른쪽 그림은 학습된 확률 모델을 이용하여 로봇이 임무를 수행하는 모습[47].

Fig. 25. Left: Kinesthetic teaching process, Middle: Learning process - Gaussian mixture model. Here, x- and y-axes indicate temporal and spatial information, Right: Reproduction process using the Gaussian mixture model [47].

을 수행할 수 있을 것이다. 확률 기반 접근 방법은 여러 번의 모방을 통해 확률 모델을 학습한다. 이 확률 모델은 모방된 행동들의 다양성을 보장할 수 있고, 작업을 성취하기 위해 만족해야 하는 제약 조건을 학습하고, 표현하는 것을 가능하게 한다. 확률 모델 접근 방법은 이러한 일반화가 가능한 것이 하나의 장점이다. 또한, 이러한 확률 기반 방법들은 주로 조작자의 행동 데이터를 모방하여 모델을 생성한다. 다시 말해, 모델 생성 시 조작자가 모델 생성에 직접적으로 관여하지 않고, 오로지 조작자의 행동 데이터를 기반으로 모델 파라미터를 학습하는데 관심을 갖는다.

확률 모델 기반의 접근방법들에서 가장 일반적으로 사용되는 방법은 은닉 마르코프 모델을 사용하는 방법이다. Tso 등, Yang 등, Lee 등, 그리고 Calinon 등과 같은 다양한 연구자들은 센서 수준의 관측 모델을 갖는 은닉 마르코프 모델을 기반으로 작업자의 행동들을 확률적으로 모델링 하였다. 이들은 은닉 마르코프 모델을 인식에 사용하는 것뿐만 아니라 샘플링과 보간법 등을 이용하여 작업을 재현하였다[43-46]. 최근에 Calinon 등은 은닉 마르코프 모델이 시간을 포함할 수 없는 단점을 보완하기 위해 시간과 위치 정보까지 포함하는 은닉-세미 마르코프 모델을 제안하였다. 이를 통해 좀 더 강인한 시간 정보와 공간 정보의 표현 및 사용이 가능해졌다[47].

은닉 마르코프 모델을 사용하는 대신에 Lee등은 가우시안 혼합 모델과 가우시안 혼합 회귀와 같은 확률 기반의 방법들을 이용하여 학습 데이터를 표현하고, 재생성하는 방법을 제안하였다[48]. 그림 25는 확률 모델을 이용한 접근 방법의 하나의 예이다. 그림에서처럼 조작자의 행동을 모방을 이용한 접근 방법의 대표적인 예(즉, 가우시안 혼합 모델)를 보여준다.

더불어 최근에는 몇 가지 최적화 방법을 이용하여 학습된 확률 모델에서 최적화된 움직임을 추출하는 연구가 활발히 진행되고 있다[49]. 또한, 작업 수행 시 좀 더 정밀한 레퍼런스 경로를 제공하기 위한 발전된 확률 모델링 기법도 제안되

고 있다[50]. 이와 같은 확률 기반 접근 방법은 인지 제어를 위해 현재의 주변 상황의 변화에 따라 상황에 맞게 기준 경로를 제공하는 것부터 좀 더 정밀한 기준 경로들을 제공하는 것까지 고려하고 있다.

2.2 인공신경망 기반 접근방법

1970년대 MLP (Multi-layer perceptron)의 등장으로 1980년대 활발한 연구가 진행되던 인공신경망은 네트워크가 계층이 많고 스케일이 커졌을 경우 학습의 어려워지는 것과 기존의 MLP로는 동적이고 시간적인 패턴의 문제를 다루기가 어렵다는 점이 문제가 되었다. 때맞춰 support vector machines (SVM)의 등장으로 1990년대의 인공신경망은 다소 침체기를 맞게 된다. 계층이 많은 네트워크의 경우 파라미터의 수가 엄청나게 많아지기 때문에 역전파(backpropagation)를 통한 최적화 과정에서 지역 최소값에 수렴하는 경향이 있다. 이를 극복하기 위해 최근 딥러닝(deep learning) 방법이 개발되었는데 구체적으로, 레이어별로 최적화를 수행하고 쌓는(stacking) 사전학습 과정을 통해서 전역 최소값 근처로 초기화한 상태에서 역전파를 최적화를 수행하는 것이다[36,66]. 또한, 시간적 패턴의 문제를 다루는 것이 가능한 recurrent neural network (RNN)의 등장 [53,54]으로 인공신경망은 근래에 다시 주목을 받고 있다.

인간의 인지적 행동들은 계층적 제어시스템에 기반하고 있다는 것은 잘 알려진 뇌과학 분야의 연구 결과이다. 재사용이 가능한 단위 행동들은 결합하여 복잡한 행동들을 구성하고 이러한 단위행동들의 재현과 단위행동들의 결합방식은 환경의 변화에 밀접하게 연관되어 수행된다. 이러한 특성은 돌발적인 환경의 변화에 적절히 대응할 수 있도록 하는 필수적 요소이다. 한편 뇌가 불확실성이 포함된 상황에서 수행하는 인식과 행동의 패턴은 베이저안 이론에 가깝다는 베이저안 브레인 이론이 있다. 이 중 [51,52]에 따르면 결국 베이저안 브레인이란 뇌에 의해서 예측한 센서 정보와 실제로 획득한 센서정보의 차이를 최소화 하도록 뇌가 시냅스를 조정하여 내재적 표현(internal representation)을 수정하는 것이라고 주장하고 있다.

인공 신경망 모델에 기반한 여러 인지 제어 연구들 중에서도 Tani 등은 위에서 언급한 바와 같은 뇌과학 연구에 동기부여 됐을 뿐만 아니라 기존의 유사한 연구들과는 다른 특성을 나타내고 있다. 기존의 유사 연구들이 설계에 의한 명시적 계층구조를 사용하거나 단위행동을 결합하기 위한 인공신경망 이외의 추가적인 모듈을 사용하는 것과는 달리 Tani 등은 하나의 인공신경망이 자기조직화를 통해서 계층을 생성하고 환경변화에 대해서 적절한 인지 제어를 할 수 있는 모델을 제안하였다[53].

제안된 모델은 CTRNN (Continuous Time Recurrent Neural Network)에 기반하고 있다. CTRNN은 미분방정식으로 표현되는데 각 뉴런의 발화는 현재 시간의 입력 값과 이전 시간에서의 뉴런들의 상태에 의해서 결정된다. 따라서 CTRNN은 RNN 과 함께 주로 시간적으로 연속된 정보를 모델링 하기 위해 사용된다.

그림 26은 제안된 CTRNN의 행동생성 과정을 보여주고 있다. 전체 뉴런들은 크게 입/출력 유닛과 컨텍스트 유닛, 목표

그림 26. CTRNN 기반의 인지 제어 방법[53].

Fig. 26. CTRNN-based cognitive control.

(goal) 유닛으로 나뉘어 지고 컨텍스트 유닛은 미분방정식의 시간 상수(time constant)에 따라 패스트/슬로우 컨텍스트 유닛으로 나뉘어 진다. 패스트 유닛은 재사용이 가능한 단위 행동을 인코딩하고 있고 슬로우 유닛은 이러한 단위 행동들의 조합에 대해서 인코딩 하고 있다. 슬로우 유닛중에는 목표 유닛이 있는데 목표로 하는 작업에 따라서 초기화된다.

모델에 주어지는 두 종류의 입력은 로봇의 관절(proprioceptive) 센서 입력 m_t 과 카메라를 통한 비전 입력 s_t 이다. 현재 시점에서의 입력정보 m_t 와 s_t 에 기반하여 모델은 다음 시간에서의 m_{t+1} 와 s_{t+1} 을 예측하고 이 중 $st+1$ 은 로봇의 목표 제어 신호로 주어진다. 로봇의 행동에 의한 환경의 변화, 예를 들면 다루고자 하는 물체의 변화와 변경된 관절 정보는 다시 다음 시간에 피드백 정보로 주어지게 된다. 이는 정적 모델인 MLP과 다른 중요한 차이점이다. 해당 모델의 학습과정은 베이지안 브레인 이론 과도 밀접한 연관관계가 있다. 학습과정에서는 그림 25에 나타나있는 모델로부터 예측된 센서 정보와 그림에는 없지만 목표로 주어지는 센서 정보가 비교되고 그 차이가 최소화 되도록 뉴런간의 가중치를 조절한다.

해당 모델은 휴머노이드 로봇이 양 손으로 간단한 물체를 다루는 작업에 사용되었다. 이때 로봇이 처한 상황이 학습할 때와 다르게 주어진다. 예를 들면 물체의 초기 위치가 달라지거나 로봇의 작업 도중 사람의 작업 방해등이 이루어진다. 때문에 로봇은 학습된 모델에 기반하여 상황에 적절하게 행동해야 하는 어려움이 있다. 이를 그림 25의 CTRNN을 이용하여 해결하는 것을 보였다.

2.3 강화학습기반 접근방법

강화학습(Reinforcement Learning)이란 이름 그대로 에이전트 또는 제어기가 수행한 행동에 대해 환경으로부터 얻은 보상을 기준으로 행동을 수행하는 정책을 조금씩 수정하여 최적의 정책을 선택하도록 하는 학습방법이다[55]. 기존 제어방식이 제어기에 요구되는 모델의 파라미터를 설계자가 결정하거나, 휴리스틱을 사용하는데 반해서, 강화학습에서는 스스로의 경험을 통해 제어기의 최적 파라미터를 학습할 수 있다는 장점이 있다. 따라서 자율주행[56], 보행로봇[57], 로봇팔의 조작[58]등의 복잡한 실제환경에서의 비선형 제어기의 학습방법으로 이용되어 왔다.

많은 강화학습 방법이 어떤 상태에서 어떤 행동을 했는지를 평가하는 가치 평가 함수를 정의하고, 미래에 기대되는 보상을 최대화하는 상태-행동 규칙을 동적 계획법(dynamic

programming)에 의해 찾는 방법을 사용하고 있다. 구체적으로, 어떤 상태에서 어떤 행동을 하는 것이 어느 정도의 가치가 있는지를 정의하는 행동-가치함수(action-value function), $Q(s, a)$ 를 정의한다. 미래의 기대되는 보상의 총합을 최대화할 수 있도록 이 행동-가치함수를 시행착오를 통해 배우는 것이 강화학습의 목적이다. 학습이 완료되면 특정 상태 s 에서 가장 가치가 높은 행동 a 를 고르는 것으로 최적의 제어가 가능해진다. 하지만 이런 접근방법은 배워야 할 함수의 개수가 상태공간의 종류와 행동의 종류의 곱으로 나타나기 때문에, 상태공간의 크기가 커질수록 학습에 필요한 경험과 학습시간이 비현실적으로 많아진다는 문제가 있다. 특히, 다족 보행의 제어문제 같은 다차원의 센서와 작동기를 갖는 문제에서 상태공간의 크기가 기하급수적으로 늘어나기 때문에 현실적으로는 이런 문제에 적용이 불가능하다.

최근에는 상태 행동규칙을 매개변수화 된 정책(parameterized policy)으로 정의한 후에 적은 횟수의 시행착오를 통해 이 정책을 개선하도록 하는 접근방법이 복잡한 제어 문제에 활용되고 있다[59-61]. 매개변수화 된 정책에 의한 강화학습은 매개변수들의 집합 θ 에 의해 어떤 상태 s 에서 어떤 행동 a 를 하는 것이 좋을 지가 결정되는 매개변수화 된 정책 $\pi_\theta(a|s)$ 을 이용한다.

휴머노이드 팔의 제어와 관련된 매개변수화 된 정책기반 강화학습들이 다음과 같은 2차 미분방정식을 이용하여 시스템을 정의한다[62,63].

$$m\ddot{v} = K(g - s) - D\dot{v} + (g - s_0) \frac{\sum_i \theta_i \psi_i(t)}{\sum_i \psi_i(t)}, \quad (1)$$

$$m\dot{s} = v$$

여기에서, s 는 현재상태를 나타내는 변수이고 s_0 는 초기상태, g 는 목표상태를 나타내는 변수이다. 그리고 $\psi_i(t)$ 는 가우시안 커널 같은 i 번째 기저함수이며, θ_i 는 i 번째 매개변수이다. 이 식에서 매개변수에 의해 조절되는 $(g - s_0) \sum_i \theta_i \psi_i(t) / \sum_i \psi_i(t)$ 항은 예측에 의해 제어신호를 생성하는 역할을 한다. 매개변수가 결정이 되면 이 미분방정식의 결과는 상태들의 행동들의 궤적 $\tau = \langle a_0, a_1, \dots, a_N \rangle$ 를 생성한다. 궤적 τ 가 생성되었을 때의 보상을 $R(\tau)$ 라고 하면, 제어기가 동작하는 동안의 기대되는 보상의 합은 매개변수에 대한 함수로서 다음과 같이 정의된다.

$$J(\theta) = \int P_\theta(\tau | \pi) R(\tau) d\tau \quad (2)$$

식 (2)에 대한 변화율 $\nabla J(\theta)$ 를 구하면, 강화학습 문제는 연속 함수에서의 최적화 문제로 전환된다. 이 방법은 모든 상태공간에 대한 행동 규칙을 배우는 기존의 방법과 달리, 매개변수만을 배우기 때문에 학습을 위한 탐색공간을 줄일 수 있는 장점이 있다. 또한 플랜트의 특징을 미분방정식에 반영할 수 있기 때문에, 제어대상을 보다 정확하게 모델링하는 것이 가능하다.

최근 들어, 강화학습 관련한 최적화 문제의 해가 어떤 궤적의 적분을 하는 것과 동일함을 보이고, 이를 마르코프-체인-몬테카를로 (MCMC) 방법으로 샘플링을 통해서 구하는

것이 가능하고, 기존의 강화학습의 해를 구하는 방법보다 더 효율적임이 제시되었다[64,65].

이와 같이, 매개변수화 된 정책결정 방식의 강화학습에 기반한 제어방법은 플랜트에 대한 정확한 모델 없이 비선형의 높은 자유도를 갖는 제어기의 파라미터를 스스로 학습할 수 있기 때문에 높은 수준의 자율성이 필요한 실제 제어문제에 적용하여 성공적인 결과를 보였다.

3. 인지제어의 도전 과제

인지 컨트롤 시스템의 도전과제를 참고문헌 [36]을 참조하여 다음과 같이 제시한다.

3.1 숙련된 작업자처럼 동작하는 인지제어 시스템

복잡한 환경에서 높은 수준의 자율성을 갖는 인지 제어를 위해서는 (1) 상황의 인지에 기반하여 장기적인 목표를 달성 하기에 적합한 제어신호를 생성, (2) 풀고자 하는 제어문제에 대한 정교한 모델에 기반한 예측제어, (3) 환경의 변화에 대한 적응과 학습 등의 능력이 제어기에 요구된다.

인지 제어기의 모델이 정교하지 않을 때에는 피드백을 받아서 제어신호와의 오차를 줄이는 방향으로 동작하지만, 반복적인 경험을 통해 정교한 모델을 학습하게 되면 피드포워드 제어기처럼 동작한다. 인지제어기의 최종형태라고 볼 수 있는 사람의 예를 들어보도록 하자. 자동차를 주차시키는 과정에서 초심자는 차와 주변환경간의 관계를 끊임없이 확인하는 피드백을 통해 오랜 시간을 들여 차를 원하는 위치에 주차시킬 수 있다. 하지만, 오랜 경험을 통해 정교한 모델을 가지고 있는 숙련된 운전자는 거의 피드백을 받지 않고도 원하는 위치에 주차시킬 수 있다. 극도로 숙련된 사람은 포크레인으로 과일을 썰거나, 붓글씨를 쓰는 수준의 제어를 하는 것도 가능하다. 이는 모두 제어문제에 대해 정교한 모델을 습득했기 때문에 가능한 일이다.

3.2 인지적 자원을 적응적으로 관리하는 실시간 시스템

오늘날의 복잡한 자동화 시스템은 정보를 모으거나 통합하고 장기적, 즉각적인 우선순위 결정하거나, 주변 환경의 변화에 따라 주의 집중할 대상을 변경하는데 있어서 사람이 중요한 역할을 한다. 이러한 능력은 백개, 천개, 혹은 그 이상의 센서와 액추에이터가 유지되어야 하는 스케일이 매우 큰 시스템에서는 특별히 중요하다. 예를 들자면 빌딩 자동화, 공장자동화, 교통 통제 시스템 등이 그러하다. 하지만 이러한 예는 우리의 일상 생활에서도 존재한다.

우리는 승객과 대화하거나 라디오를 들으면서도 자동차를 고속도로에서 운전할 수 있다. 하지만 만약 다른 차가 갑자기 우리 앞에 나타난다면 우리는 즉시 우리의 주의 집중을 안전을 확보하기 위한 필수적 대상으로 전환한다. 이 순간에 우리의 인지적 자원은 유연하게 재조정된다. 이러한 유연하고 견고한 행동은 오늘날의 대부분의 리얼타임 시스템의 정적이고 미리 정해진 작업의 스케줄링 방식과는 차이가 있다.

생물학적 인지와 컴퓨터 기반의 집중(attention) 관리 시스템의 차이는 컨트롤 해야 하는 시스템의 스케일이 커짐에 따라 더욱 극명해진다. 학습은 문제의 스케일이 커질수록 더욱 중요하다. 사람은 어떤 정보가 중요하고 어떠한 무수히 많은 정보들은 무시되어도 상관없는지를 오랜 시간 동안 학습한다. 즉, 복잡한 시스템을 조정하고 감독하는 능력은 오랜 시

간의 경험에 의해서 획득된다.

이러한 생물학적 인지능력에 비추어 볼 때 컴퓨터 기반의 시스템은 자원 관리나 학습, 적응성 등에 있어서 더욱 많은 성능향상이 요구된다. 문제는 과연 이것을 위해서 어떤 제어 방법이 필요한 것이며, 이런 제어 방법을 위해 어떤 일반화된 플랫폼이 필요한지이다. 또한 특정 응용분야를 위해서는 일반화된 플랫폼을 기반으로 추가적으로 무엇이 필요한 것인지도 요구된다. 이러한 이슈는 제어분야의 연구와 또 다른 분야의 연구간의 협업을 통해서 해결될 수 있을 것으로 보인다.

3.3 무경험 상황에서의 제어

앞서 언급한 것처럼 현재 대부분의 제어 시스템들은 잘 정립된 환경에서 일반적으로 발생할 수 있는 조건들 하에서 잘 동작되도록 디자인 되어 왔다. 예를 들어, 가장 낮은 수준의 제어를 보더라도 PID 제어기 조차도 모터를 움직이기 위한 제어 값을 결정하기 위해 여러 신호를 사용하여 그런 응답 신호들을 조절할 것이다. 비록 수학적으로 좀 더 세련되게 표현되었을지 모르지만, 다변량 예측 제어기(multivariable predictive controllers) 또한 개념적으로는 이와 유사하다 - 그것은 하나의 규정된 알고리즘을 이용하여 (이런 경우를 모델 기반이라고 부른다) 센서 데이터를 처리하고 저수준의 제어기나 작동기에 그 출력 결과를 제공한다. 사실 잘 정립된 조건하에서 제어 시스템을 동작 시키기 위해서는 추가적으로 필요한 정보가 별로 없다. 그러나 갑작스럽고 모델링 되어 있지 않은 상황이 발생되었을 경우 (센서 또는 작동기의 실패, 플랜트에서의 갑작스러운 변화, 또는 커다란 외력 등)에는 어떻게?

자동 시스템은 이런 점을 해결하기 위해 여분의 장치들부터 실패 인지 시스템, 안전을 위한 정지 시스템, 다수의 우발적 사건들을 다루기 위한 다양한 전략들을 가지고 있다. 그러나 이들은 인간 조작자가 경험하지 못한 상황에서 반응하는 방법과 질적으로 차이가 존재한다.

물론 그러한 응급 상황들에 대해 적절한 반응들을 모델 또는 프로그래밍 하는 방법이 있다. 그러나 상상할 수 있는 모든 상황에 대해 적절한 모든 반응들을 생성하는 것은 불가능하다 (그러나 빅 데이터를 이용하여 그러한 다수의 상황에 대해 적절한 반응들을 생성하는 것이 가능할 수도 있다.) 이와 같은 전략이 전부냐 제로냐 (All-or-nothing)일 필요는 없다. 때문에 다음과 같은 문제들에 대한 답을 찾는다면 우리는 그러한 무경험 상황에서 인간과 대응을 할 수 있는 제어 시스템을 개발할 수 있을 것이다. 갑작스러운 상황이 발생하였을 때 인간의 도움 없이 우도(likelihood)를 통한 성능 평가 등을 통해 페일-세이프(fail-safe) 알고리즘들을 디자인할 수 있는 체계적인 제어 방법을 개발할 수 있는가? 그런 디자인을 통해 제어 능력이 지속적으로 향상될 수 있는가? 그런 디자인들이 갑작스러운 상황에 발생하였을 때 온라인으로 적응적으로 적용될 수 있는가? 다시 말해, 제어 시스템이 그런 갑작스러운 사건에 직면하였을 때 온라인으로 배울 수 있는가? 개별적 제어 시스템들에서 발생한 갑작스러운 사건에 대한 데이터베이스를 통해 획득된 지식들을 통해 전체 시스템에 일반화하여 적용시킬 수 있는가? 이 밖에도 인지 제어 연구라는 방향간에는 아직 뺄지 않은 많은 곡식들이 존재한다.

그림 27. 지능기술의 역할.

Fig. 27. Role of intelligence techniques.

VI. 맺음말

지금까지 지능제어 개념의 정체성에 대하여 논의하였으며, 주요한 기법으로서 퍼지기반제어, 학습제어 그리고 인지제어에 대하여 기술하였다. 세상 일은 복잡해지고 풀어야 할 문제도 점점 많아지는데, 수학적으로 타이밍 있게 다룰 수 있는 경우는 다소 제한적이라는 사실(그림 27)을 감안할 때, 이러한 겹을 좁히기 위한 방법으로 본 논문에서 다룬 여러 가지 지능제어기술이나 소프트웨어기술을 눈여겨볼 필요가 있다. 얼마 전, 필자의 동료교수로부터 들은 에피소드가 생각난다. 그가 최근 제출한 한 제안서에 “무인자동화”란 용어를 사용하였는데, 이 단어에 대하여 “지능자동화”란 단어로 고칠 것을 주문 받았다는 것이다. 얼핏, 유행을 좇는다는 의미로도 들리지만, 따지고 보면, 해당 자동화 문제를 주어진 자원과 시간제한 하에서 효과적으로 손쉽게 활용할 수 있어야 한다는 공학적 당위성으로도 해석할 수 있다. 향후, 노약자나 장애인을 위한 “스마트 홈”에서와 같이 우리에게 주어질 많은 현실적 문제에 인간 중심적이며 인간이 보다 안전하게 이용할 수 있는 인간친화시스템 (Human-friendly System) [67]으로 설계·구현하는 데에 지능(제어)기술이 적극 이용될 것으로 기대된다.

REFERENCES

- [1] K. S. Fu, “Learning control systems and intelligent control systems: An intersection of artificial intelligence and automatic control,” *IEEE Trans. on Automatic Control*, AC-16, 1971.
- [2] D. A. White and D. A. Sofge, *Handbook of Intelligent Control: Neural, Fuzzy and Adaptive Approaches*, Van Nostrand Reinhold, 1992.
- [3] K. M. Passino, “Bridging the gap between conventional and intelligent control,” *Control Systems, IEEE*, vol. 13, no. 3, pp. 12-18, 1993.
- [4] G. A. Bekey, “Autonomous robots: From biological inspiration to implementation and control,” The MIT Press 2005.
- [5] P. J. Antsaklis, “Intelligent control, encyclopedia of electrical and electronics engineering,” vol. 10, pp. 493-503, John Wiley & Sons, Inc., 1999.
- [6] G. N. Saridis, “Toward the realization of intelligent controls,” *Proc. IEEE* 67 (1979).
- [7] Z. Bien, W.-C. Bang, D.-Y. Kim, and J.-S. Han, “Machine intelligence quotient: Its (MIQ) measurements and applications,” *fuzzy sets and systems*, vol. 127, pp. 3-16, 2002.
- [8] J. Gerard Wolff, “The SP Theory of Intelligence: Benefits and Applications,” *Information* 2014, 5, pp. 1-27.
- [9] Bien, Zeungnam, *Fuzzy Logic Control (in Korean)*, Hongreung Science Book Publishers, 1999.
- [10] C. J. Harris, *Advances in Intelligent Control*, Taylor & Francis 1994.
- [11] C. W. de Silva, *Intelligent Control: Fuzzy Logic Applications*, CRC Press Inc., 1995.
- [12] L. A. Zadeh, “A theory of approximate reasoning,” in *Machine Intelligence*, vol. 9, J. Hayes, et al. (ed) New York, Halstead Press 149-194, 1979.
- [13] L. A. Zadeh, “Fuzzy sets,” *Information and Control*, vol. 8, pp. 338-353.
- [14] Z. Bien, Y.-J. Lee, S.-H. Lee, K.-H. Shim, and S.-W. Bang, “A new benchmark system for evaluation of intelligent controllers: an yo-yo system,” *Proc. of the 4th IEEE International Conference on Fuzzy Systems (FUZZ-IEEE/IFES '95)*, Yokohama, Japan, vol. 3, pp. 1361-66, Mar. 1995.
- [15] C. J. Harris, C. G. Moore, and M. Brown, *Intelligent Control: Aspects of Fuzzy Logic and Neural Nets*, World Scientific 1993 (Chapter 5).
- [16] K. M. Passino and S. Yurkovich, *Fuzzy Control*, Addison-Wesley, pp. 301-390, 1998.
- [17] M. Sugeno and G. T. Gang Fuzzy Modeling and Control of Multilayer Incinerator, *Fuzzy Sets and Systems* 18, 329-461986.
- [18] H.-C. Myung, Z. Z. Bien, and Y.-T. Kim, *Stabilization of Direct Adaptive Fuzzy Control Systems: Two Approaches*, Fuzzy Control - Synthesis and Analysis (Shehu S. et al.) WILEY, 2000.
- [19] J.-S. R. Jang, C.-T. Sun, and E. Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice-Hall, 1997.
- [20] Z. Bien and W.-K. Song, “Blend of soft computing techniques for effective human-machine interaction in service robotic systems,” *Fuzzy Sets and Systems*, vol. 134, pp. 5-25, 2003.
- [21] Z. Pawlak, *Rough Sets: Theoretical Aspects of Reasoning about Data*, Kluwer Academic Publishers, 1991.
- [22] J. M. Mendel, <http://sipi.usc.edu/~mendel/report>
- [23] A. M. Meystel and J. S. Albus, *Intelligent Systems: Architecture, Design, and Control*, Wiley, 2002.
- [24] Y. Z. Tsypkin, “Adaptation, learning, and self-learning in automatic systems,” *Automat. Remote Control (USSR)*, vol. 27, no. 1, 1966.
- [25] S. W. Lee, O. Prenzel, and Z. Bien, “Applying human learning principles to user-centered IoT systems,” *Computer (Flagship publication of IEEE Computer Society)*, vol. 46, no. 2, pp. 46-52, Feb. 2013.
- [26] P. J. Antsaklis, “Intelligent learning control,” *IEEE Control Systems*, vol. 15, no. 3, pp. 5-7, Jun. 1995.
- [27] Y.-T. Kim and Z. Bien, “Robust self-learning fuzzy controller design for a class of nonlinear MIMO systems,” *Fuzzy Sets and Systems*, vol. 111, pp. 117-135, 2000.
- [28] H.-E. Lee, Y.-M. Kim, and Z. Zenn Bien, “Intelligent human behavior learning system for smart home,” *International Conference on Human-Computer Interaction*, Las Vegas, USA, 2005.
- [29] H.-E. Lee, K.-H. Park, and Z. Z. Bien, “Iterative construct Probabilistic Fuzzy rule base from Numerical Data,” *IEEE Transactions on Fuzzy Systems*, 2007.
- [30] Z. Bien and J. X. Xu (ed), *Iterative Learning Control: Analysis,*

- Design, Integration and Applications, Kluwer Academic Publishers, 1998.
- [31] K.-H. Park and Z. Bien, "Intervalized iterative learning control for monotone convergence in the sense of sup-norm," *International Journal of Control*, vol. 78, no. 15, 2005.
 - [32] X. Ruan, Z. Bien, and K.-H. Park, "Decentralized iterative learning control to large-scale industrial processes for nonrepetitive trajectory tracking," *IEEE Tr. on SMC-Part A*, vol. 38, no. 1, 238-252, 2008.
 - [33] Z. Bien and K. M. Huh, "Higher-order iterative learning control algorithm," *IEE Proceedings*, vol. 136, no. 3, pp. 105-112, May 1989.
 - [34] I. H. Suh, Y. B. Park, G. Zhang, S. H. Lee, and W. Y. Kwon, "Homosapiens and Cognitive Robot," *Korea Journal of Information Science*, vol. 30, no. 12, Dec. 2012.
 - [35] R. C. Arkin, *Behavior-based Robotics*, MIT Press, 1998.
 - [36] Hinton, G. E., Osindero, S. and Teh, Y., "A fast learning algorithm for deep belief nets," *Neural Computation*, vol. 18, no. 7, pp 1527-1554, 2006.
 - [37] S. Schaal, "Is imitation learning the route to humanoid robots?" *Trends in Cognitive Sciences*, vol. 3, no. 6, pp. 233-242, 1999.
 - [38] G. H. Lim, I. H. Suh, and H. Suh, "Ontology-based unified robot knowledge for service robots in indoor environments," *IEEE Trans. On SMC, Part A*, vol. 41, no. 3, pp. 492-509, 2011.
 - [39] L. Atzori, A. Lera, and G. Morabito, "The Internet of Things: A Survey," *Computer Networks*, vol. 54, no. 15, pp. 2787-2805, 2010.
 - [40] M. Buss, S. Hirche, and T. Samad, "Cognitive Control," *The Impact of Control Technology*, IEEE Control Systems Society, 2011.
 - [41] M. Hjelm, C. H. Ek, R. Detry, and K. Renaud, "Sparse summarization of robotic grasp data," *Proc of IEEE International Conference on Robotics and Automation*, 2013.
 - [42] I. H. Suh, S. H. Lee, J. P. Hwang, and G. N. Han, "Task Skill Learning based on Imitation," *The Journal of Korea Robotics Society*, vol. 8, no. 4, Oct. 2011.
 - [43] S. K. Tso and K. P. Liu, "Hidden Markov model for intelligent extraction of robot trajectory command from demonstrated trajectories," *Proc. of IEEE ICIT*, pp. 294-298, 1996.
 - [44] J. Yang, Y. Xu, and C. S. Chen, "Human action learning via hidden markov model," *IEEE Trans. Syst. Man Cyb.*, vol. 27, no. 1, pp. 34-44, 1997.
 - [45] D. Lee and Y. Nakamura, "Stochastic model of imitating a new observed motion based on the acquired motion primitives," *Proc. of IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 4994-5000, 2006.
 - [46] S. Calinon and A. Billard, "Learning of gestures by imitation in a humanoid robot," *imitation and social learning in robots, humans and animals: behavioural, social and communicative dimensions*, Cambridge Univ. Press, pp. 153-177, 2007.
 - [47] S. Calinon, F. Guenter, and A. Billard, "On learning, representing, and generalizing a task in a humanoid robot," *IEEE Trans. on SMC, Part B*, 2007.
 - [48] S. H. Lee, I. H. Suh, S. Calinon, and R. Johansson, "Learning basis skills by autonomous segmentation of humanoid motion trajectories," *Proc. of IEEE International Conference on Humanoid Robots*, pp. 112-119, 2012.
 - [49] S. Calinon, F. Guenter, and A. Billard, "Goal-directed imitation in a humanoid robot," *Proc of IEEE International Conference on Robotics and Automation*, pp. 299-304, 2005.
 - [50] S. H. Lee, G. N. Han, and I. H. Suh, "Skill learning using temporal and spatial entropies for accurate skill acquisition," *Proc of IEEE International Conference on Robotics and Automation*, pp. 1323-1330, 2013.
 - [51] K. Friston, "The free-energy principle: a unified brain theory?", *Nature*, vol. 11, no. 2, pp. 127-138, 2010.
 - [52] K. Friston, "The history of the future of the Bayesian brain," *NeuroImage*, vol. 62, no. 2, pp. 1230-1233, 2012.
 - [53] Y. Yamashita and J. Tani, "Emergence of functional hierarchy in a multiple timescale neural network model: a humanoid robot experiment," *PLoS Computational Biology*, vol. 4, no. 11, e1000220, 2008.
 - [54] J. Tani, M. Ito, and Y. Sugita, "Self-organization of distributedly represented multiple behavior schemata in a mirror system: reviews of robot experiments using RNNPB," *Neural Networks*, vol. 17, no. 8-9, pp. 1273-1289, 2004.
 - [55] R. S. Sutton and A. G. Barto, *Reinforcement learning: An introduction*, Cambridge University Press, 1998.
 - [56] H. R. Beom and H. S. Cho, "A sensor-based navigation for a mobile robot using fuzzy logic and reinforcement learning," *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 25, no. 3, pp. 464-477, 1995.
 - [57] J. Morimoto, G. Cheng, C. G. Atkeson, and G. Zeglin, "A simple reinforcement learning algorithm for biped walking," in *Robotics and Automation, 2004. Proc. of 2004 IEEE International Conference on Robotics and Automation*, vol. 3, pp. 3030-3035, 2004.
 - [58] J. Peters, S. Vijayakumar, and S. Schaal, "Reinforcement learning for humanoid robotics," *Proc. of the Third IEEE-RAS International Conference on Humanoid Robots*, pp. 1-20, 2003.
 - [59] S. Schaal, J. Peters, J. Nakanishi, and A. Ijspeert, "Learning movement primitives," in *Robotics Research*, Springer, pp. 561-572, 2005.
 - [60] F. Stulp and S. Schaal, "Hierarchical reinforcement learning with movement primitives," *Proc. of 11th IEEE-RAS International Conference on Humanoid Robots*, pp. 231-238, 2011.
 - [61] J. Peters and S. Schaal, "Reinforcement learning of motor skills with policy gradients," *Neural Networks*, vol. 21, no. 4, pp. 682-697, 2008.
 - [62] S. Schaal, "Dynamic movement primitives-a framework for motor control in humans and humanoid robotics," in *Adaptive Motion of Animals and Machines*, Springer, pp. 261-280, 2006.
 - [63] P. Pastor, H. Homann, T. Asfour, and S. Schaal, "Learning and generalization of motor skills by learning from demonstration," *Proc. of IEEE International Conference on Robotics and Automation*, pp. 763-768, 2009.
 - [64] E. Theodorou, J. Buchli, and S. Schaal, "Learning policy improvements with path integrals," *Proc. of International Conference on Artificial Intelligence and Statistics*, pp. 828-835, 2010.
 - [65] H. J. Kappen, "An introduction to stochastic control theory, path integrals and reinforcement learning," *Proc. of AIP Conference*, vol. 887, p. 149, 2007.
 - [66] G. Hinton and R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504-507, 2006.

- [67] K.-H. Park, Z. Bien, et.al, "Robotic smart house to assist people with movement disabilities," *Autonomous Robot*, vol. 22, pp. 183-198, 2007.

부록(Appendices)

A. 지능적 행동의 속성 리스트(List of Various Aspects of Intelligent Behaviors [9])

(1) Learning	(11) Reliability
(2) Adaptivity	(12) Robustness
(3) Reasoning	(13) Reactivity
(4) Problem-solving	(14) Homeostasis
(5) Planning	(15) Self Correction
(6) Decision-making	(16) Error Optimality
(7) Autonomy	(17) Speed
(8) Reconfiguration	(18) Reusability
(9) Extensibility	(19) Uncertainty Handling
(10) Fault Tolerance	(20) Complexity Handling

B. ANFIS 운영 알고리즘 구조[19]

$$O_{1,i} = \mu_{A_i}(x), \text{ for } i = 1, 2, \text{ or } \\ O_{1,i} = \mu_{B_{i-2}}(y), \text{ for } i = 3, 4$$

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} : \text{generalized bell function}$$

$\{a_i, b_i, c_i\}$: **premise parameters**

Layer 2. $O_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y), \quad i = 1, 2.$

Layer 3. $O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2.$

Layer 4. $O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2. \quad \{p_i, q_i, r_i\}$

Layer 5. $O_{5,i} = \sum_i \bar{w}_i f_i = \sum_i w_i f_i : \text{overall output}$

Determination of membership function

C. 학습의 타입(Typology of Learning [23])

- Type 1. Signal learning
- Type 2. Learning of stimulus-response (S-R) couples
- Type 3. Learning associations between S-R units, and labeling the associations
- Type 4. Learning S-R classes, or clustering the S-R couples
- Type 5. Discriminating objects with the same labels
- Type 6. Rule learning
- Type 7. Concept learning
- Type 8. Problem solving
- Type 9. Probably approximately correct (PAC) concept learning
- Type 10. Model-free PAC learning
- Type 11. Distribution-free PAC learning
- Type 12. Learning concepts from attribute-based instances (ABI)
- Type 13. Learning by concepts from structured instances
- Type 14. Learning by complementary discrimination
- Type 15. Learning by testing the environment and generalization (TEG learning)
- Type 16. Q-Learning
- Type 17. Repetition learning
- Type 18. Reinforcement learning
- Type 19. Error correction learning
- Type 20. Specific error correction learning

D. 학습자(Learner)의 기능(Functions)

- (1) To enhance the vocabulary of *perception*
- (2) To enhance the vocabulary of *representation*
- (3) To enhance the vocabulary of *storage*
- (4) To enhance the vocabulary and the arsenal of rules for *comparison*
- (5) To enhance the vocabulary, the arsenal of rules, and the precision of *evaluation*
- (6) To enhance the vocabulary, the arsenal of rules, and the set of meta-rules of the *response-generating* production system
- (7) To enhance the vocabulary of response available for actuation
- (8) To enhance the number and the adequacy of the *techniques for generalization*

변 증 남

1969년 서울대학교 전자공학과 졸업. 1972년 아이오와대학교 대학원 전자공학 석사. 1975년 아이오와대학교 대학원 수학 석사. 1975년 아이오와대학교 대학원 전자공학 박사. 1976년~1977년 아이오와대 객원 조교수. 1977년~2009

년 KAIST 전자전산학부 전기 미 전자공학전공 교수. 1990년~1995년 한국퍼지학회 초대회장. 1991년~1992년 KAIST 교수협의회 회장. 2001년 제31대 대한전자공학회 회장. 2003년~2005년 국제퍼지시스템학회 회장. 2004년~2006년 한국로봇공학회(현 한국로봇학회) 초대 및 2대 회장. 2005년~2009년 한국전력 석좌교수. 2007년 미국전기전자학회(IEEE) 석학회원(Fellow). 2009년~현재 유니스트 석좌교수. 현재 KAIST 명예교수. 관심분야는 인간-로봇의 상호작용 시스템분야와 생활보조로봇공학 분야.

서 일 홍

1977년 서울대학교 학사. 1979년 한국과학기술원 석사, 1982년 한국과학기술원 박사. 1982년~1985년 대우중공업 기술연구소 선임연구원. 1987년~1988년 미시간대학교 객원연구원. 1985년~2000년 한양대학교 전자공학과 교수. 2000

년~2012년 한양대학교 공과대학 컴퓨터공학부 교수. 2004년~2006년 한양대학교 정보통신대학장. 2006년~2007년 대한전자공학회 시스템 및 제어 소사이어티 회장. 2006년~2010년 네트워크기반 지능형로봇 교육센터장. 2008년 한국로봇학회 회장. 2009년~현재 로봇 특성화 대학원 사업단(RoSEC) 단장. 2010년~2012년 한국공학한림원 일반회원. 2013년~현재 한국공학한림원 정회원. 2010년 12월 한국 100대 기술과 주역에 선정 (로봇 제어기 분야), 2011년 12월 로봇 분야 유공자 국무총리 상 수상. 2013년~현재 한양대학교 융합전자공학부 교수. 관심분야는 인간수준의 Manipulation, Planning, Navigation, Recognition을 위한 Robot Intelligence.