

□ 기술해설 □

복수전략 학습(Multistrategy Learning)

명지대학교 윤병주* · 김병천**

● 목	차 ●
1. 서 론	3. 범용 복수전략학습 모형
2. 복수전략 학습	3.1 Inferential theory of learning
2.1 Symbolic 학습전략 결합에 의한 방법	3.2 MTL(Multistrategy Taskadaptive Learning)
2.2 Symbolic/Subsymbolic	4. 맺음말

1. 서 론

주변 환경의 변화에 유연하게 대처해 나갈 수 있는 능력은 학습에서부터 비롯된다. 인간은 본능 형태의 지식을 갖고 태어난 후, 계속 학습함으로써 지식의 폭을 넓혀 나간다. 우리는 사물들 간의 인과관계나 특성들을 관찰하여 스스로 깨달아 알기도 하고(unsupervised learning), 선생님의 가르침에 따라 새로운 지식을 배우기도 하며(supervised learning), 다른 사람의 지적에 따라 올바른 지식을 습득하기도 한다(reinforcement learning).

이와 같은 지식 습득의 주요 수단인 인간의 학습 능력을 모형화하여 기계에 이식해보려는 시도는 인공지능 연구의 주요 과제가 되어 왔지만, 학습 자체가 가지는 인지과학적인 복잡성 때문에 특정 분야의 작은 영역(domain)에서만 사용 가능한 여러 방법들이 제안되었으며[3, 19], 또한, 학습된 지식이 지식기반시스템(knowledge-based systems)과 같은 지식처리의 기반지식으로 사용되는 현실적인 필요성 때문에 대부분의 학습시스템들은 학습된 지식을 IF-THEN 형태의 규칙으로 표현하고 있다. 따

라서, 본고에서는 대상이 되는 영역(domain)의 주변환경(environment)이나 표본자료(examples)로부터 추론하여 규칙(rule) 형태의 지식을 추출해내는 일을 기계학습(machine learning)이라 정의한 후, 이런 범주에 드는 방법들만 고찰한다.

기계학습시스템을 설계하려면 먼저 학습전략(learning strategy)을 결정해야 한다. 학습전략이란 지식추출을 위해서 어떤 계산모형(computational mechanism)을 사용해야 하며, 어떤 추론방법을 사용해야 하는가의 전략을 말한다. 예컨대, ID3 방법[18]의 학습전략은 결정목구조(decision tree)의 계산모형에다 귀납법(induction)을 추론규칙으로 사용하며, EBL[14]은 규칙 형태의 계산모형에 연역법(deduction)을 추론규칙으로 사용하며, KT 알고리즘[6]은 다층신경망 모형에 귀납법을 사용한다.

학습시스템의 차이는 학습전략의 차이에 기인한다고 말할 수 있다. 기계학습 연구의 초창기부터 제안된 많은 연구 결과들은 한가지의 학습전략을 사용한 학습시스템, 즉, 단일전략 학습시스템(monostrategy learning system) 개발이 주류를 이루어 왔다. 단일전략 학습방법은 구현의 간편함과 특정 영역에서 만족할 만

*중신회원
**정회원

한 성능을 나타내 보임으로서 그 가치를 인정 받았지만, 단일전략이 가지는 근본적인 한계성을 극복할 수 없는 단점이 있다. 따라서, 두 가지 이상의 학습전략을 함께 사용함으로써 상대적인 장점을 살릴 수 있는 새로운 학습방법이 제안되었는데, 이를 복수전략 학습(multistrategy learning) 방법이라 한다[11,12].

본 고의 전개는 다음과 같다. 먼저, 2장에서 근래에 발표된 몇 가지의 복수전략학습시스템들을 알아보고 3장에서는 R. S. Michalski가 제안한 범용 복수전략학습 모형을 소개한다.

2. 복수전략 학습

근래에 발표된 복수전략학습 방법들을 살펴 보면, 주로 단일전략학습 방법의 근본적인 제약 부분을 완화·제거하거나 또는 다른 학습전략의 장점을 덧붙일 목적으로 복수전략이 채택되고 있음을 알 수 있다[1,2,7,20,23]. 이들 복수전략은 각각의 단일전략을 덧붙이는 방법에 따라 연결형(cascade type)이나 결합형(integration type)으로 설계된다. 연결형이란 한 전략의 출력 결과가 다른 전략의 입력으로 사용되면서 학습하는 형태를 말하며, 결합형이란 입력자료(외부에서 입력되는 표본 자료)의 유형에 따라서 학습전략을 달리하거나, 여러개의 학습전략이 상호작용하면서 학습하는 형태를 말한다. 복수전략학습에서 각 학습전략의 계산모형은 단일학습전략들을 어떻게 연합(hybrid or integrate)할 수 있는가를 결정한다. 학습전략이 사용할 수 있는 계산모형은 크게 두 가지로 나눌 수 있다. 즉, 기호(symbol) 형태로 지식을 표현할 수 있는 모형과 준기호(subsymbolic)형태로 지식을 표현할 수 있는 모형이다. 전자의 예로는 결정목구조(decision tree), 규칙, 의미네트워크(semantic network) 등을 들 수 있으며, 후자의 예로서는 신경망구조(artificial neural network), 진화 알고리즘(genetic algorithm)에서의 염색체표현 등이다. 연결형 복수전략학습에서는 다른 지식표현을 사용하는 학습전략을 연결한다 해도 전혀 문제되지 않지만, 결합형 복수전략학습에서는 상이한 지식표현의 학습전략을 결합하는데에는 어려움이 따르

로, 제안된 대다수의 결합형 복수전략학습에서는 같은 지식표현을 사용하는 전략들을 사용하여 계산모형의 전부 혹은 일부를 공유하게 하는 방식을 채택하고 있다.

2.1 Symbolic 학습전략 결합에 의한 방법

본 절에서는 기호형 지식표현을 사용하는 계산모형들을 결합하여 설계한 복수전략학습 방법들[2, 4, 15, 16, 17, 26] 중에서 EITHER와 GEMINI 두 가지를 소개한다.

2.1.1 EITHER [15]

EITHER(Explanation-based and Inductive Theory Extension and Revision) 시스템은(대상이 되는) 영역 전문가의 식견을 바탕으로 작성한 규칙집합(이것을 domain theory라 함)을 실례(examples)를 바탕으로 수정하여 정제할 수 있도록 설계한 학습시스템이다. EITHER에서 사용하는 계산모형은 규칙이며, 추론 방법으로 연역법(deduction), 추측법(abduction), 귀납법(induction)을 필요에 따라 연결 형태로 사용한다. EITHER 시스템의 구성은 그림1과 같으며, 학습과정은 아래와 같다.

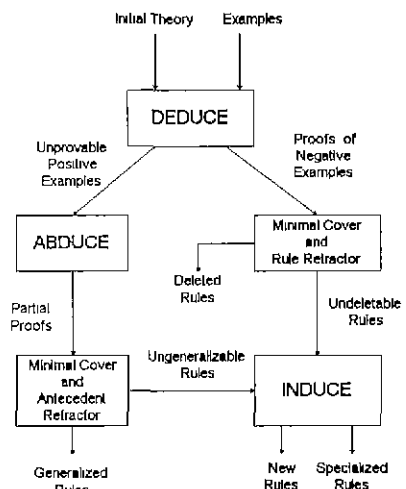


그림 1 EITHER 시스템의 구조

EITHER 시스템의 입력은 domain theory와 각 경우에 대한 결과가 명시되어 있는 실례

들(examples)이다. EITHER 시스템은 실례에 대하여 연역모듈이 정확한 결과를 도출하는가를 검사하여 만약 정확한 결과를 도출하지 못한다면, 주어진 실례를 바탕으로 하여 규칙집합을 수정한다. 수정은 두 가지 방법으로 이루어진다. 첫째, domain theory에서 정확하게 연역되어야 하는 실례(이것을 positive example이라 함)를 연역하지 못하는 경우에는 추측모듈에 넘겨서 positive example을 정확하게 식별할 수 있도록 관련 규칙들을 더 일반화시키거나, 귀납모듈로 넘겨서 새로운 규칙을 만들어 domain theory에 추가한다. 둘째, domain theory에서 연역되지 않아야 하는 실례(이것을 negative example이라 함)를 연역한 경우에는 연역과정에 관련된 규칙들을 domain theory에서 삭제하거나, 귀납모듈로 넘겨서 더 제한적인 새로운 규칙을 만들어 domain theory에 추가한다.

이와같이 EITHER 시스템은 domain theory에 표현된 지식을 기반으로 하는 연역법 및 추측법을 사용하는 학습전략과 실례를 사용하는 귀납적 학습전략을 병행함으로써, domain theory를 효과적으로 수정·정제할 수 있는 방법을 보였다.

2.1.2 GEMINI [4]

GEMINI 시스템은 analytical learning, conceptual clustering, 및 inductive learning을 feedback-loop형태로 결합한 복수전략학습의 한 모형으로서, analytical learning을 위해서 EBL(Explanation-Based Learning)을 사용하였다. GEMINI의 구조는 그림2와 같으며, 지식베이스(rulebase)에는 불완전하지만 domain theory가 들어 있다. GEMINI의 입력은 어떤 개념(goal concept)을 나타내는 이름과 그 개념을 뒷받침해 줄 수 있는 실례들(examples)이다. 어떤 개념 이름과 한 실례가 입력되면 EBL 모듈은 domain theory에서 해당 개념을 기술한 규칙들을 참조하여 conceptual clustering 모듈로 넘겨준다. 만약, 해당 개념이 domain theory에 없거나 있다 하더라도 입력된 실례를 설명할 수 없다면, inductive learning 모듈은 EBL 모듈에서 넘겨진 설명, 개념 및 실

례를 바탕으로 영역 지식을 구성할 속성들의 관계를 그래프 형태로 만들어 GBM(Generalization-Based Learning)에 저장한다. 따라서, inductive learning의 입력은 GBM에 저장된 케이스들 중에서 학습해야 할 개념과 관련된(positive) example들이므로, inductive learning을 보다 효율적으로 할 수 있고, GBM에 저장된 설명들로부터 추출되는 정보를 이용함으로써 정확하고 간결한 규칙을 domain theory에 추가할 수 있다.

2.2 Symbolic/Subsymbolic 학습전략 결합에 의한 방법

기호(symbol) 형태로 지식을 표현하는 계산 모형과 준기호(subsymbolic)형태로 지식을 표현하는 계산모형을 함께 사용하는 복수전략 학습 방법은 연결형을 근간으로 하는 혼합학습(hybrid learning)에서 주로 사용되는 방법이다. 이러한 학습방법은 domain theory를 정제하기 위한 수단으로, 신경망에의한 학습방법을 연결하거나 진화알고리즘을 사용한 것이 주로 발표되었다 [1,5,7,20,24,25].

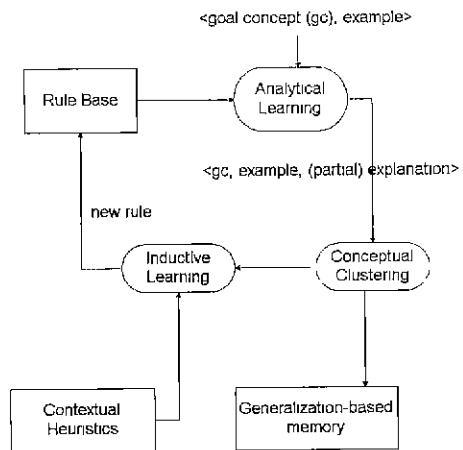


그림 2 GEMINI의 구조

본 절에서는 신경망 학습을 사용한 domain theory 정제 방법으로 제안된 KBANN과 J. W. Bala가 제안한 진화알고리즘을 사용한 Co-operative Concept Learning을 소개한다.

2.2.1 KBANN [24]

KBANN(Knowledge-Based Artificial Neural Network) 시스템은 domain theory의 불완전함을 극복할 목적으로 inductive learning 방법에다 신경망을 사용하는 학습방법을 추가한 복수전략학습 방법이다. KBANN에서 채택한 학습전략은 domain theory learning과 역전파학습(backpropagation learning)이며, 지식표현 형태는 규칙과 숫자이다.

서로 다른 지식표현을 사용하는 두 가지의 학습전략을 유연하게 연결하기 위해서, KBANN에서는 그림3과 같이 연속적으로 계산모형을 변경시키면서 학습을 수행한다. 즉, 규칙들로 표현된 domain theory를 신경망 구조로 바꾼 후, 역전파 학습을 사용하여 링크 값(weight)을 조정하고, 학습된 신경망으로부터 규칙을 다시 추출해 낸다. KBANN의 입력은 표본자료(example)이거나 표본 자료와 domain theory이다. 기호형 지식표현을 사용하는 inductive learning방법은 입력되는 실례에 민감하게 반응하고 잡음(noise)에 대해서도 취약한 특성을 나타낸다. 그러나, 신경망 구조를 사용한 학습방법은 불완전하거나 부정확한 실례(examples)에 대해서도 비교적 정확한 학습결과를 얻을 수 있고, 또 잡음에 대해서도 견고성을 가지므로 domain theory를 정제할 수 있다. 그러나, 학습된 내용이 신경망의 구조와 링크 값들에 분산되기 때문에 중복되는 규칙을 배제하여 domain theory를 재구성하는 작업이 필요하다.




그림 3 KBANN에서의 정보 흐름

는 closed-loop 형태의 복수전략학습 방법이다. 지식표현 방법은 DNF(Disjunctive Normal Form)형의 논리식과 염색체(chromosome)에 배열되는 유전인자이며, 입력으로는 표본자료(examples)가 사용된다. 기호형 inductive learning의 단점인 불완전하거나 잡음이 있는 실례(example)에서 기인하는 학습 누락과 bias에 의한 overfitting현상을 진화알고리즘이 보완해주고, 또 진화 알고리즘 본래의 느린 학습과 분산학습의 약점을 inductive learning이 줄여줌으로서 상호 상승작용을 할 수 있도록 하였다. 이 방법의 구조는 그림4와 같다. 표본자료가 입력되면 inductive learning module이 구동되어 DNF형 지식을 추출하게 되며, 이를 진화알고리즘 모듈로 넘긴다. 진화 알고리즘 모듈에서는 넘겨받은 DNF형 지식을 염색체에 배열한 후, 돌연변이(mutation) 연산과 교배(crossover) 연산을 사용하여 표본자료로서 학습을 진행하며, 학습결과로 얻게되는 최적해를 inductive learning 모듈로 되넘겨 준다. 이와 같은 과정을 반복하여 만족할 만한 수준의 개념을 찾음으로서 학습을 종료한다.

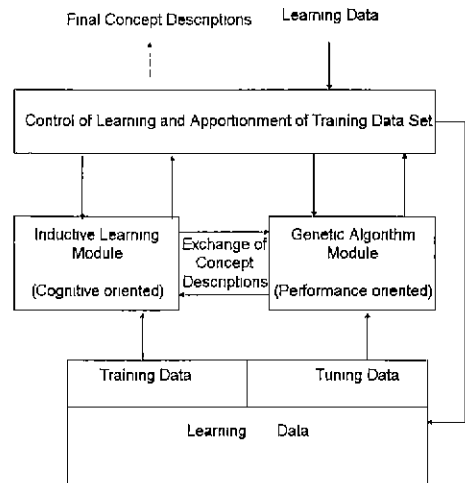


그림 4 Cooperative Concept Learning의 구조

2.2.2 Cooperative Concept Learning [1]

Cooperative Concept Learning은 inductive learning 방법과 진화알고리즘을 결합하여 상호 학습결과를 교환하면서 학습을 진행하

3. 범용 복수전략학습 모형

2장에서 소개한 바와 같이 지금까지 제안된

대다수의 복수전략학습 방법들은 inductive learning을 기본으로 하여 다른 학습 방법들을 연결 또는 결합함으로써 효과적이고 효율적인 학습을 도모하고자 하였다. 이런 방법들은 사용 영역(domain)에 의존적이고 복잡한 표본자료에 대하여 적응력을 가지지 못하므로 범용성 있는 학습방법으로 사용하기에는 어려움이 따른다. 여기서, 인간의 학습방법을 고찰해 볼 필요가 있다. 인간은 5감을 통해서 자료를 받아들여, 이미 기억하고 있는 관련 사항(혹은 케이스)을 참조하여 가장 적합한 추론방법을 찾은 후에, 이를 사용하여 추론함으로써 주어진 문제를 해결하거나 주변 상황을 인식(인지)해 나간다. 이렇게 볼 때 인간의 학습방법은 근본적으로 범용 복수전략학습을 사용하고 있다고 할 수 있다. 이와 같은 인간의 학습방법을 유추한 학습모형이 제시되었는데 R. S. Michalski가 제안한 범용 복수전략 학습모형이 그것이다 [11,12,13]. 이 학습 모형은 지금까지 제안된 복수전략학습 모형의 단점을 극복할 수 있을 뿐만 아니라(완전하지는 않지만) 잘 정의된 이론이 뒷받침하고 있다는데 그 특징이 있다.

3.1 Inferential theory of learning

컴퓨터에 의한 일반 복수전략학습 모형을 개발하기 위한 기초 이론으로 제안된 것이 the Inferential theory of learning이다. 이 이론은 컴퓨터에 의한 학습을 다음과 같이 정의한 후, 그 정의 위에서 내용을 전개하고 있다. 즉, “컴퓨터에 의한 학습(즉, 기계학습)이란 경험(examples)과 지식베이스에 축적된 지식을 바탕으로 지식베이스의 지식을 확장·수정해 나가는 과정으로서 그 과정이 목표에 의하여 선도(goal-guided process)되어야 한다.”

학습을 위해서는 학습 주체인 컴퓨터가 지식을 기억할 수 있어야 하며, 동시에 추론할 수 있는 기능을 가지고 있어야 한다. 지식베이스는 주변환경 인식을 위한 개념적 지식(conceptual knowledge)과 적응을 위한 제어지식(control knowledge)을 기반지식(background knowledge)으로 가지고 있어야 하며, 추론 결과로 만들어지는 유용한 지식도 기억할 수 있어야 한다. 학습해야 할 목표가 제시되면 적합한 추론

방법이 선정되어 지식베이스의 지식과 외부로부터의 입력을 참조하여 새로운 지식을 만들 수 있어야 한다. 이때, 만들어지는 지식은 지식베이스의 지식들로부터 연역적으로 만들어지기도 하고, 외부 자료(examples)로부터 귀납적으로 만들어지기도 하며, 외부로부터 지식 형태로 바로 입력되기도 한다. 또한, 여기서 말하는 학습 목표는 외부로부터 입력된 목표일 수도 있고, 외부 환경 인식이나 추론과정에서 만들어지는 목표일 수도 있다. 이렇게 볼 때, 학습이란

$$\text{Learning} = \text{Inference} + \text{Memorizing}$$

와 같은 방정식으로 나타낼 수 있으며, <입력, 기반지식, 새로운 지식>으로 표현되는 지식공간(knowledge space)을 목표선도(goal-guided)적으로 탐색하는 문제로 귀결시킬 수 있다. 그림 5에서 이와 같은 학습 과정을 개략적으로 보여주고 있다.

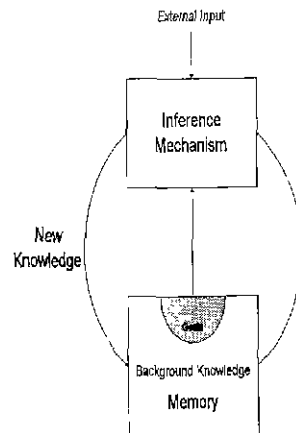


그림 5 학습 과정의 모형

학습은 학습과정(learning process; learning task)에 의해서 구체화된다. 학습과정은 일련의 지식변환(knowledge transmutation) 과정으로 볼 수 있는데, 지식변환을 통하여 컴퓨터 지식베이스의 초기 지식(initial knowledge)이 학습 목표를 만족시킬 수 있는 지식으로 만들어진다. 학습 시스템이 사용할 수 있는 추론 규칙들을 변환연산자(transmutation op-

erator)로 간주함으로써 지식 변환을 아래와 같은 함수로 표현할 수 있다.

$$O = T(I, BK)$$

여기서, I는 외부 입력 또는 입력되는 지식(input knowledge)을 말하며, BK는 기반기지식(background knowledge), T는 변환(transmutation), O는 학습목표를 만족시킬 수 있는 출력 지식(output knowledge)을 말한다.

이때, 만들어지는 지식은 지식 베이스의 지식들로부터 연역적으로 만들어지기도 하고, 외부 자료(examples)로부터 귀납적으로 만들어지기도 하며, 외부로부터 지식 형태로 바로 입력되기도 한다. 또한, 지식 변환 연산자들은 계산모형의 지식 표현에 구애받지 않으므로(independent), 설정된 학습 목표와 기반기지식 표현 방식에 따라 동적으로(dynamically) 선택될 수 있다. 따라서, 이들을 지식공간 탐색을 위한 연산자로 사용함으로써 일반적인 기계 학습 과정을 도형화할 수 있다.

3.2 MTL(Multistrategy Taskadaptive Learning)

MTL은 앞 절에서 설명한 기계학습 이론을 토대로 하여 여러 학습전략을 통합한 범용 복수전략학습 모형으로서 R. S. Michalski에 의하여 제안된 학습시스템이다. 그림6은 MTL의 구조를 보여주고 있다.

MTL 시스템의 중요한 특성은 주어진 학습 목표에 가장 적합한 학습전략을 시스템이 스스로 결정해서 학습 과정을 수행해 나가는 데 있다. 이를 뒷받침하기 위해서 multitype inference engine이 여러 종류의 추론방법을 지원한다. Selection 모듈은 설정된 학습 목표, 관련 기반기지식 및 입력을 분석한 후 최적의 학습전략을 선정해 주며, 입력 자료 중에서도 학습 목표와 관련된 입력만 통과시키는 필터 역할을 한다. 또, 지식 베이스도 여러 종류의 계산모형에서 사용 가능하도록 multitype으로 유지된다. Control 모듈은 총체적인 학습 과정을 제어한다. 즉, 학습 목표(학습 목표는 외부 사용자에 의해서 주어지기도 하고, 지식베이스에 있는

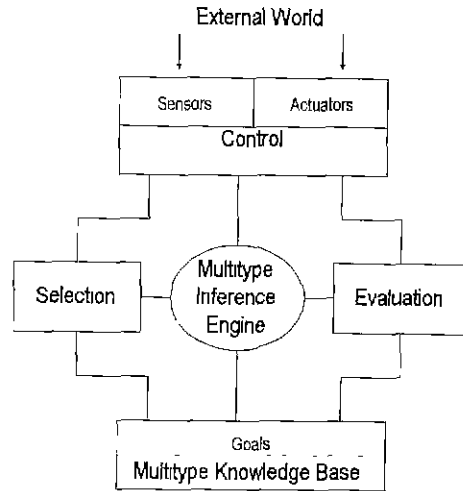


그림 6 MTL의 구조

지식을 분석함으로써 만들어지기도 하며, 한 학습 과정 중에 부학습목표(subgoal)로서 만들어지기도 한다)를 결정하여 학습 과정을 제어하며, 학습중에 요구될 수도 있는 외부의 추가 정보를 입력받기 위한 기저(mechanism)도 유지한다.

Evaluation 모듈은 학습 상황을 점검한다. 학습 과정의 각 단계에서 생성되는 지식을 학습 목표와의 관련성에 따라 평가하고 필요시 비평해 준다. 일단 유용한 지식으로 평가된 지식은 지식 베이스에 저장되어 사용된다.

이와같이 MTL은 여러 종류의 학습전략을 모두 지원할 수 있을 뿐만 아니라, 사용할 학습 전략 선택이 학습 목표에 따라 동적으로 이루어지므로 범용 기계학습시스템으로 사용될 수 있다 하겠다. 그러나, 이와 같은 시스템을 완전히 구현하기란 대단히 어려운 일이며, 이를 구현하기 위한 시도(엄밀히 말해서, MTL subset)가 시작되고 있다.

4. 맺음말

본고에서는 두 가지 이상의 학습전략을 사용하는 복수전략 학습시스템에 관하여 살펴보았다. 복수전략 학습시스템은 단일전략 학습시스템이 나타내는 편향성 문제를 해결할 수 있을 뿐만 아니라 사용된 각각의 학습전략들이 상호

상승작용을 일으켜 단일전략 학습시스템보다 훨씬 좋은 학습 효과를 나타내 준다. 복수전략 학습시스템을 설계하기 위해서는 단일전략 각각의 학습 특성을 이해하고 있어야 하며, 각 전략의 단점을 보완할 수 있고 장점을 살릴 수 있는 전략들을 선택해야 한다.

본고에서 소개한 바와 같이, 지금까지 제안된 대다수의 복수전략 학습시스템은 특정 영역에서만 사용할 수 있도록 설계되었으므로 범용 학습시스템으로 사용하기에는 무리가 따르지만 이런 경향은 당분간 지속될 듯하다. 그러나 기계학습 연구의 큰 흐름은 3장에서 소개한 MTL과 같은 범용 복수전략시스템을 지향할 것이므로 효율적인 범용 학습시스템의 출현을 기대해 본다.


참 고 문 헌

- [1] J. W. Bala, et. al., "Multistrategy Learning from Engineering Data by Integrating Inductive Generalization and Genetic Algorithms", in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds), pp. 471-487, Morgan Kaufmann, 1994.
- [2] C. Baroglio, et. al., "WHY: A System That Learns Using Causal Models and Examples", in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds), pp. 319-347, Morgan Kaufmann, 1994.
- [3] B. G. Buchanan and D. C. Wilkions (eds), *Readings in Knowledge Acquisition and Learning*, Morgan Kaufmann, 1993.
- [4] A. P. Danyluk, "GEMINI: An Integration of Analytical and Empirical Learning", in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds), pp. 189-215, Morgan Kaufmann, 1994.
- [5] L. M. Fu, "Knowledge-based Connectionism for Revision Domain Theories", *IEEE Trans. on SMC*, Vol. 23, pp. 173-182, 1993.
- [6] L. M. Fu, *Neural Networks in Computer Intelligence*, McGraw-Hill, 1994.
- [7] D. P. Greene and S. F. Smith, "COGIN: Symbolic Induction with Genetic Algorithms", *AAAI '92*, pp. 111-116, 1992.
- [8] V. Honavar and L. Uhr (eds), *Artificial Intelligence and Neural Networks*, Academic Press, 1994.
- [9] R. S. Michalski (ed.), *Multistrategy Learning*, Kluwer Academic Publishers, 1993.
- [10] R. S. Michalski and G. Tecuci (eds), *Machine Learning: A Multistrategy Approach*, Vol. IV, 1994.
- [11] R. S. Michalski, "Inferential Theory of Learning as a Conceptual Basis for Multistrategy Learning", *Machine Learning*, Vol. 11, pp. 111-151, 1993.
- [12] R. S. Michalski, "Inferential Theory of Learning: Developing Foundations for Multistrategy Learning", in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds.), pp. 3-61, Morgan Kaufmann, 1994.
- [13] R. S. Michalski, "Toward a unified theory of learning: Multistrategy task-adaptive learning", in *Readings in Knowledge Acquisition and Learning*, B. G. Buchanan and D. C. Wilkins (eds.), pp. 7-38, Morgan Kaufmann, 1993.
- [14] T. M. Mitchell, et. al., "Explanation-Based Generalization: A Unifying View", *Machine Learning*, Vol. 1, pp. 47-80, 1986.
- [15] R. J. Mooney and D. Ourston, "A Multistrategy Approach to Theory Refinement", in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds.), pp. 141-164, Morgan Kaufmann, 1994.
- [16] K. Morik, "Balanced Cooperative Modeling", *Machine Learning*, Vol. 11, pp. 217-235, 1993.
- [17] M. Pazzani, "Learning Causal Patterns: Making a Transition from Data-Driven to Theory-Driven Learning", *Machine Learning*, Vol. 11, pp. 173-194, 1993.
- [18] J. R. Quinlan, "Induction of Decision Trees", *Machine Learning*, Vol. 1, pp. 81-106, 1986.
- [19] J. Shavlik and T. Dietterich (eds.), *Readings in Machine Learning*, Morgan Kaufmann, 1990.
- [20] J. W. Shavlik and G. G. Towell, "Combining Explanation-Based Learning and Arti-

ficial neural Network”, Proc. of the 6th Int. Workshop on the Machine Learning, pp. 90-92.

- [21] G. Tecuci, “Plausible Justification Trees : A Framework for Deep and Dynamic Integration of Learning Strategies”, Machine Learning, Vol 11, pp. 237-262, 1993.
- [22] G. Tecuci, “An Inference-Based Framework for Multistrategy Learning”, in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds.), pp. 107-138, Morgan Kaufmann, 1994.
- [23] S. B. Thrun, et. al., “The Monk’s Problems : A Performance Comparison of Different Learning Algorithms”, CMU-CS-91-197, 1991.
- [24] G. G Towell and J. W. Shavlik, “Extracting Refined Rules from knowledge-Based Neural Networks”, Machine Learning, Vol. 13, pp. 71-101, 1993.
- [25] H. Vafaie and K. De Jong, “Improving a Rule Induction System Using Genetic Algorithms”, in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds.), pp. 453-469, Morgan Kaufmann, 1994.
- [26] B. L. Whitehall and S. C. Lu, “Theory Completion Using Knowledge-based learning”, in *Machine Learning*, Vol. 4, R. S. Michalski and G. Tecuci (eds.), pp. 165-187, Morgan Kaufmann, 1994.

윤 병 주



1975 경북대학교 수학과(학사)
 1982 한국과학기술원 전산학과(석사)
 1994 Florida State University 전산학과(박사)
 1975~1977 육군본부
 1977~1979 KAL 시스템개발실 근무
 1982~현재 명지대학교 컴퓨터공학과 부교수
 관심분야: Machine Learning, Knowledge-based System, Hybrid Intelligent Systems, Logic Programming

김 병 천



1988 한남대학교 전자계산학과(학사)
 1990 숭실대학교 전자계산학과(석사)
 1994~현재 명지대학교 컴퓨터공학과 박사과정 재학중
 1993~현재 안성산업대학교 전자계산학과 전임강사
 관심분야: Machine Learning, Knowledge-based System, Machine Vision
