

인지과학, 제16권 제4호, 2005, 369~386.

교수내용지식을 위한 하이브리드 지식 표현 기법

A Hybrid Knowledge Representation Method for Pedagogical Content Knowledge

김용범
Yongbeom Kim)

오 필 우
(Pillwo Oh)

김 영 식
(Yungsik Kim)

요 약 지능형 교수 시스템(ITS: Intelligent Tutoring System)이 기존의 CAI의 제한적 기능을 극복하고, 내장한 지식베이스에 의해 다양한 학습자들의 변인들을 고려한 개별화된 학습 환경을 제공하지만, 교육현장에는 교수내용지식 표현 방법의 부재와 투자 비용의 비효율성으로 인하여 실제적인 개발물은 전무한 상태이다. 이러한 문제점을 해소하기 위하여 ITS에서의 지식표현 기법과 구축된 지식베이스의 재사용에 대한 연구가 필요하다. 교수내용지식의 특성을 고려하여 본 연구에서는 기존의 신경논리망의 한계점을 해결할 수 있도록 지식의 다중 결합체 구성, 이를 이용한 학습의 맥락 설명을 연구의 대상으로 삼았다. 또한 형성된 지식결합체는 군집화하여 지식베이스 객체로 사용하고, 결합체의 자기 학습에 의해 적응적인 지식베이스 객체로의 성장 가능성을 제고한다. 따라서 본 연구에서는 신경논리망의 논리추론, 그리고 인지구조에서 노드의 위상적 불변성을 근거로, 교수내용지식과 객체지향적 개념이 포함된 '확장된 개념의 신경논리망(X-Neuronet: eXtended Neural Logic Network)'을 제안하고, 이 기법에 대한 타당성을 검증하였다. X-Neuronet은 표현의 대상이 되는 지식을 관성과 가변성을 가지는 방향성 결합체로 정의하고, 표현을 위한 기본 개념, 노드의 처리와 연산을 위한 논리연산자, 노드값과 가중치의 결정, 노드활성을 위한 전파 규칙, 학습 알고리즘 등을 제공한다.

주제어 지능형교수시스템, 지식표현, 신경논리망

Abstract Although Intelligent Tutoring System(ITS) offers individualized learning environment that overcome limited function of existent CAI, and consider many learners' variable, there is little development to be using at the sites of schools because of inefficiency of investment and absence of pedagogical content knowledge representation techniques. To solve these problem, we should study a method, which represents knowledge for ITS, and which reuses knowledge base. On the pedagogical content knowledge, the knowledge in education differs from knowledge in a general sense. In this paper, we shall primarily address the multi-complex structure of knowledge and explanation of learning vein using multi-complex structure. Multi-Complex, which is organized into nodes, clusters and uses by knowledge base. In addition, it grows a adaptive knowledge base by self-learning. Therefore, in this paper, we propose the 'Extended Neural Logic Network(X-Neuronet)', which is based on Neural Logic Network with logical inference and topological inflexibility in cognition structure, and includes pedagogical content knowledge and object-oriented conception, verify the validity. X-Neuronet defines that a knowledge is directive combination with inertia and weights, and offers basic conceptions for expression, logic operator for operation and processing, node value and connection weight, propagation rule, learning algorithm.

Keywords Intelligent Tutoring System, Knowledge Representation, Neural Logic Network

* 한국교원대학교, 연구 세부분야: ITS, 지식표현, 컴퓨터교육

충북 청원군 강내면 다락리 산 7, 한국교원대학교 컴퓨터교육과

전화: 043-230-3786, E-mail: kybhj@hanmail.net

서 론

지능형 교수 시스템(ITS: Intelligent Tutoring System)이 기존의 CAI의 제한적 기능을 극복하고, 내장한 지식베이스에 의해 다양한 학습자들의 변인들을 고려한 개별화된 학습 환경을 제공하여(김성식, 1996) 현대의 정보사회에서 영역 전문가를 대신할 가장 효율적인 교수 방법으로 인식되고 있으나, 실제적인 개발을 위한 연구는 미미한 실정이다. 이는 ITS 구축을 위한 교육적 지식 표현방법의 부재와 투자 비용의 비효율성에서 기인한다. 따라서 문제 해결을 위한 출발점은 효율적인 지식 표현 방식에서 찾아야 한다.

일반적으로 모든 지식을 포함할 완전한(compact) 표현기법은 존재하지 않으므로 대부분의 지식표현은 필요에 의해 복수개의 기법을 병행 사용한다(Minsky[1]). 이에 임의의 특정 영역 지식은 그 나름대로의 특수성 때문에 해당 영역을 표상하기 위한 적절한 표현 방식은 지속적으로 연구·발전시키고 있으나, ITS에 적합한 지식표현 방법에 대한 연구는 전무한 상태이다.

본 연구는 ITS에서의 지식표현 기법과 구축된 지식베이스의 재사용에 관심을 둔다.

교육에서의 지식은 ‘교수내용지식(pedagogical content knowledge)’이라고 정의하며, 일반적인 의미의 지식과는 달리, 학습 환경, 학습자의 학습 출발점과 심리 등 여러 지식 외적 요인에 의존하여 지식의 표현 상태가 변형되어 학습자에게 전달되어야 한다는 것을 전제로 한다(Cochran, 1993. 김대현, 2003). 이 교수내용지식은 고정된 요소와 가변적 요소의 공존, 학습자 적응적 지식, 구성요소 결합에 의한 지식

신뢰도의 변화의 개념을 포함한다.

이러한 교수내용지식의 개념에 비추어 교수 내용지식의 표현을 위한 신경논리망(neural logic network)의 도입은 타당성을 갖는다.

하지만, ACES(Low, 1991)을 기점으로 출발한 신경망에서의 논리추론의 적용, 추론 네트워크의 구성(Henry, 2001. Chia, 2004.) 등 신경논리망에 대한 연구가 충분히 진행되어 왔지만, 지식에 대한 개념적 차이 때문에 교육에서의 직접적 적용은 용이치 않다.

기존의 신경논리망은 지식을 노드간 단일 결합된 유한 방향성 그래프 형식으로 표상하여 논리 추론과 불확실한 지식의 표상을 해결 할 수 있으나, 지식의 군집화와 전체적 흐름 파악의 어려움, 그리고 추론 과정 설명을 위한 다양한 경로의 제공에는 한계가 있었다. 본 연구의 출발점은 노드의 방향성 결합으로 유의미한 노드 결합체를 생성한다는 것을 전제로 하여(Quinlan, 1991), 상이한 결합 규모와 구조를 가지고, 객체화가 가능한 노드 결합체를 구성하는데 있다. 노드의 유의미한 결합횟수가 많을수록 지식의 의미가 명확해지며, 또한 ‘학습에서의 맥락(강남형, 2001)’이라는 관점에서, 적응적 지식표현을 위해서는 결합체 구조의 지식표현이 교수내용지식의 표현에 적합하기 때문이다. 또한 형성된 결합체는 노드간의 위상과 결합 방향을 추출하여 일정 크기의 지식베이스 프레임을 형성하여 객체화할 수 있다는 장점을 갖는다. 이 객체화는 인간의 인지구조는 개체와 무관하게 노드들은 위상적으로 동일하다(강창동 외, 2001)는 가정을 전제로 한다.

구성된 결합체는 객체화되어 동일한 프레임을 가지는 소규모 지식베이스 객체를 생성하

고, 이 객체간의 통신 및 대화에 의하여 각각 개별화된 객체로 성장하여 이를 지능적 협동 학습이나 원격교육에 사용할 기초적 구성요소를 제공한다.

또한, 이는 최근 SCORM(Share of Contents Reference Model), 학습 객체(learning object) 등으로 연구가 진행되고 있는 자원의 객체지향 개념(Wiley, 2002; 임진호, 2003)을 통해 ‘개발의 효율성’을 제고할 수 있어, 시스템 개발에 소요되는 비용을 감소시키는 효과도 얻을 수 있다.

따라서 본 연구에서는 신경논리망의 논리추론과 가중치의 가변성(Chia, 2004), 그리고 인지 구조에서 노드의 위상적 불변성(강창동 외, 2001)을 근거로, 교수내용지식과 객체지향적 개념이 포함된 ‘확장된 개념의 신경논리망(X-Neuronet: eXtended Neural Logic Network)’을 제안하고, 이 기법에 대한 타당성을 검증한다.

이론적 기초

교수내용지식: 교육에서의 지식의 의미

교육내용은 매우 다양한 의미를 지니지만, 일반적으로 지식 영역, 기능 영역, 가치 영역의 집합체로 정의한다(Hyman, 1973). 따라서 일반적으로 지식이라 함은 교육에서는 교육내용이라 할 수 있으나, 이 교육내용은 실제의 교수-학습 상황에서는 학생의 능력과 배경에 적합하고 교수법적으로 적절한 형태로 변환이 발생한다(Livingston, 1989). 단순한 내용지식은 교육적으로는 무의미한 것이며, 학생들이 파악할 수 있도록 수업에로 변환한 후에야 그 의미를 가지며, 또한 이러한 변환은 교사를

해당 학문 분야의 학자들과 구별해주는 독특한 과정이라고 할 수 있다(Shulman, 1986).

Gudmundsdottir(1988)는 교사의 교수 추론과 실천의 과정을 교수목적으로 이루어진 교재에 대한 이해의 과정, 교육내용의 변환의 과정, 교수 실천의 단계(수업의 과정), 교수-학습 성과 평가, 교수에 대한 반성과 재구성, 그리고 전반적인 내용에 대한 새로운 이해의 과정으로 구분하고, 여기에서 교육내용 변환의 과정에 의해 변환된 교과 내용은 유추, 보기, 예증, 실연, 은유 등의 형식으로 표상화된다. 즉 교사는 유추나 보기, 은유 등의 방법을 통해 학습자에게 효과적으로 내용을 전달한다. 이러한 교육 내용의 의미있고 적극적인 변환은 궁극적으로 교수-학습의 상황에서 교수자의 ‘교수내용지식’으로 나타나게 된다.

교수내용지식은 교과의 특정한 내용지식의 구조를 학습자를 고려하여 전달하는 방식으로, 교사의 전문적인 자질로서 중시되고, 또한 교사를 일반적인 내용전문가나 교육학자와 구별해 주는 독특한 지적 기반이라 할 수 있다.

교수내용지식에 대하여 Shulman(1986)은 교수 가능성이 가장 적합한 내용의 측면들을 구현한 것으로 정의하고 있다. 예컨대 이러한 지식은 그 교과의 내용을 다른 사람에게 이해 할 수 있도록 제시하는 방법에 관한 지식을 말하는 것이다. 또한 교수내용지식에는 특정한 주제를 배우는데 있어서의 무엇이 그 과정을 어렵게 만들거나 쉽게 만드는가에 대한 지식도 포함된다(이돈희, 1998).

이런 면에서 볼 때 교수내용지식은 가르치는 내용의 성격과 이에 따르는 제반 요인에 따라 그 모습을 달리한다고 볼 수 있으며, 당연히 내용에 대한 깊은 이해를 요구하게 된다.

이것은 교사의 전문성과 관련한 논의로 이어지게 된다.

신경논리망

신경논리망은 기존의 신경망을 이용하여 삼진 부울 논리(three-valued boolean logic)를 효과적으로 모델링할 수 있는 토대를 제공해주며 나아가서 확률 논리나 퍼지 논리를 수행하도록 확장할 수 있다. 기존의 부울 논리는 두 가지 진리값 "TRUE"와 "FALSE"를 기반으로 개발되었지만 삼진 부울 논리에는 "UNKNOWN"이라는 진리값이 하나 더 포함된다. 신경논리망은 노드와 링크를 이용한 유한 방향성 그래프로 나타낼 수 있으며, 모든 링크에는 가중치에 해당하는 순서쌍 (x, y) 가 할당된다.

각 노드는 순서쌍으로 구성이 되는 세 가지의 활성값(activation value) 중에 하나를 가지게 된다.

$(1, 0)$ for "TRUE"

$(0, 1)$ for "FALSE"

$(0, 0)$ for "UNKNOWN"

이러한 신경논리망에서 임의의 Q노드의 활성값을 결정하기 위해 사용되는 전파규칙은 다음과 같다.

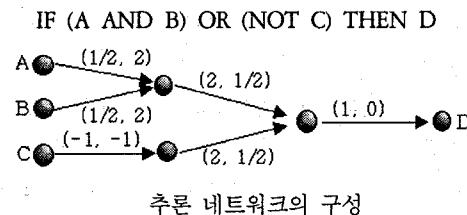
노드 Q와 연결된 모든 노드들의 집합을 $\{P_1, P_2, P_3, \dots, P_n\}$, P_i 의 노드값은 (a_i, b_i) 라고, 노드 P와 노드 P_i 를 연결하는 링크의 가중치를 (x_i, y_i) 라 하면,

단계1 : $a = \sum a_i x_i$ 와 $\beta = \sum b_i y_i$ 를 계산한다.

단계2 : 노드 P의 활성값을 다음과 같이 계산한다.

$$\text{Act}(Q) = \begin{cases} (1, 0) & \text{if } \sum (\alpha - \beta) \geq 1 \\ (0, 1) & \text{if } \sum (\alpha - \beta) \leq -1 \\ (0, 0) & \text{otherwise} \end{cases}$$

이러한 신경논리망을 이용하여 논리 연산을 표현할 수 있으며, 논리 연산에 대한 정의를 이용하면 임의의 논리 연산자들을 포함하고 있는 규칙들을 신경논리망을 이용하여 쉽게 표현할 수 있다. 다음은 임의의 규칙을 신경논리망을 이용하여 표현한 예이다.



네트워크 상에서의 각 노드는 규칙에서의 하나의 명제 또는 논리 연산자에 대응하며 이와 같은 노드와 링크로 구성되는 신경논리망을 이용하여 추론이 이루어지는 과정을 표현할 수 있다.

개발 및 적용 가능성 탐색

교육에서 학습 내용, 즉 교수내용지식을 바라보는 관점은 다음과 같은 특징을 가지고 있다고 할 수 있다(Livingston, 1989).

첫째, 교수내용지식은, 교육내용과 같이 고정지식이 존재하는 동시에, 이들 사이의 가변성향을 포함하고 있으며,

둘째, 교육의 실제적 구현이 교수-학습 활동의 행위로서 표출되는 것처럼 교육에서의 지식 자체도 활동에 투입되는 경우에 관심의 대상이 된다는 것을 전제로 하고,

셋째, 교수내용지식의 표상은 대상 학습자에 의존한다는 것이다. 즉 학습자에게 적용되는, 지식의 개별화에 관심을 가진다.

또한, ACES(Low,1991)를 시점으로 신경망에서의 논리추론의 적용에 대한 연구가 지속적으로 이루어졌고, 이를 근거로 등장하게 된 신경논리망의 주요 관심은 추론 네트워크의 구성(Henry,2001. Chia,2004)등, 임의의 특정 요소를 찾는 탐색의 기법에 대한 연구이다 (Lee,2001). 하지만 기존의 신경논리망은 단일 깊이의 노드 연결과 적합한 추론 결과의 활성화에 관심을 가지기 때문에, 결과 추론보다는 다양한 과정 설명에 비중을 두고 있는 교육에서의 직접적 적용은 용이치 않다. 이에 교수 내용지식의 표현은, 지식구성요소의 단순 연결 보다는 유의미한 노드의 결합적 형식이 적합하다(Jonassen,1989)는 것은 타당성을 가진다.

또한, 단일 결합을 가지는 유한 방향성 그래프인 기존의 신경논리망은, 효과적인 교수 내용지식을 모델링하기 위해서는 다중 결합을 허용하는 유한 방향성 결합체를 구성할 수 있도록 변형이 이루어져야 함을 뜻한다. 이러한 방향성 결합체는 기존의 신경논리망을 이용하여 할 수 없었던 ‘학습의 맥락(강남형,2001)’을 표상할 수 있다. 또한 결합의 방향, 규모 등을 표현함으로써, 지식의 전체적인 구조를 파악 할 수 있다.

본 연구에서는 이를 위해 노드의 방향성 다중 결합체 구성에 관심을 둔다.

결합된 노드의 결합체는, 자기 학습에 의해 서 개개의 학습자에게 적용 가능한(adaptable) 지식 구조를 제공 가능하고, 이 결합체가 학습자에게 할당되는 경우에는 학습 내용에 대한 위치 및 방향적 요소만이 아니라, 학습의

맥락까지도 할당할 수 있다는 점, 군집화된 결합체에 근접 지식과의 위상 관계도 파악할 수 있다는 점, 결합에 의한 의미의 명확성 심화 등의 잇점을 얻을 수 있다.

이는 신경논리망은 지식에서의 선택 기능에 적당하며, 지식의 의미를 내포하기에는 부적절하다는 점을 해소할 수 있다.

결합체는 그 자체만으로도 의미를 갖는 객체로 취급되어질 수 있다. 즉, 일정 수준 이상의 규모를 가지는 결합체는 그 자체로서 지식 베이스 객체로 사용 가능하다. 결합체의 지식 베이스 객체로서의 사용은 SCORM, 학습객체 등의 개념(Wiley,2002. 임진호,2003)에서와 같이 개발의 효율성을 제고할 수 있으며, 이는 1990년 이후 지속적으로 관심을 두고 있는 자원의 재사용성을 위한 객체지향 개념에의 접근도 가능하다.

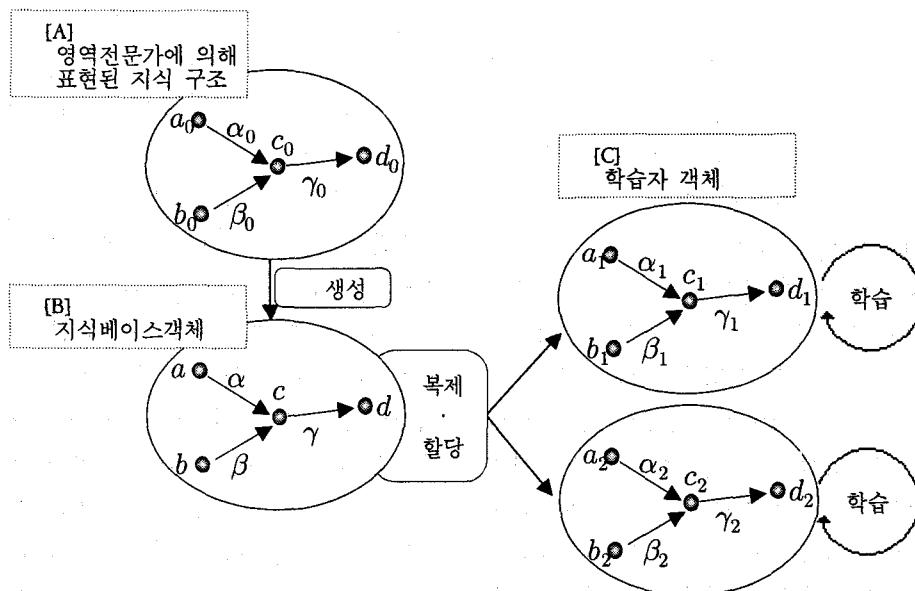
또한 객체화된 결합체가 학습자에게 할당되는 경우, 개인에게 적용하는 개별적 지식베이스의 구축의 기회를 보장한다.

본 연구는 다음과 같이 기존의 신경논리망과 차별화된다.

첫째, 다른 크기의 노드 결합을 보장하며, 결합에 의해 새로운 노드가 생성된다..

본 망은 결합적 구조를 가진다. 이 결합적 구조는 단순 방향성 연결뿐만 아니라, 연결에 의해 새로운 노드가 생성되는 생산적 결합을 포함한다. 따라서 본 연구에서의 결합의 의미는 다중 결합에 의해 지식의 의미가 더욱 명확해진다는 점, 지식의 신뢰도를 높이기 위한 수단으로 결합이 발생하는 점, 노드의 결합에 의해 새로운 의미의 노드가 생성된다는 것이다.

둘째, 노드의 결합과 결합체의 자기 학습에 의해 군집화가 일어난다.



[그림 1] 지식베이스 객체의 적용 가능성 탐색

이는 군집화에 의해 중심 개념이 발생하며, 교수내용지식에서는 학습의 주제나 단원을 중심으로 군집화가 발생할 수 있다.

셋째, 군집화된 결합체를 하나의 지식 객체로 사용 가능하다는 것이다. 객체의 사용은 개발의 효율성 뿐만 아니라, 교수내용지식에서는 단원별, 또는 주제별로 하나의 객체를 생성하여 모델링하기가 쉽다는 장점을 가진다. 이에 비추어 소규모의 지역적인 주제를 가지고 있는 경우, 본 표현 기법은 강력한 가능성 을 제공할 수 있다.

넷째, 객체화로 인하여 결합체의 착탈과 이동이 용이하다. 즉 본 연구에 의한 객체는 'portable하다'라고 정의할 수 있다.

다섯째, 결합체는 자기 학습에 의해서 개별 성장 가능성을 갖는다. 이에 따라 적응적인 지식구조를 모델링할 수 있다.

여섯째, 기존의 신경논리망이 주어진 규칙

에 의해 노드의 활성화에 관심을 가지지만, 본 연구는 구축된 결합체에서 설명 적합한 다양한 경로의 탐색에 관심을 가진다.

따라서 본 표현 기법은, [그림 1]과 같은 과정을 통하여 지식베이스 객체를 생성하고, 이 결합 객체를 이용하는 학습자 적응형 ITS 모형의 개발 가능성을 제공한다.

신경논리망의 확장 (X-Neuronet: a Extended Neural Logic Network)

X-Neuronet에서의 지식의 개념

지식의 표현 기법은 지식을 바라보는 관점, 즉 지식의 정의에 의존한다고 할 수 있다. 본 연구에서는 지식의 개념을 노드간의 연결망 구조, 수리적 계산에 의한 연결 상태의 활성으

로 인지상태를 표상하는 연결주의(connectionism)적 관점에서 출발하여(이정모, 1996), 신경논리망의 논리추론과 가중치의 가변성(Chia, 2004), 그리고 인지구조에서 노드의 위상적 불변성(강창동 외, 2001)을 기저로 다음과 같은 전제를 설정한다.

첫째, 지식은 추상적인 공간 내에서 독립적으로 존재하는 단순 지식들이 사고의 흐름과 일정한 맥락(강남형, 2001)에 따라 결합하여 새로운 지식을 생성한다. 이러한 과정의 반복을 통해 규모가 커지며, 의미가 명확해지는 지식 결합체를 구성한다. 결합에 의해 지식이 정교화된다(Bower, 1981; Mandler, 1967). 또한 이렇게 형성된 지식 결합체는 그 자체만으로도 소규모 유의미한 지식구조를 형성한다.

둘째, 지식 사이의 연결에는 방향성이 존재하여 형성되는 지식은 연결 방향과 연결 노드에 의해 다른 지식을 표상한다. 지식에는 지식 자체의 신뢰도와 지식과 지식 사이의 연결 가중치가 존재한다(Henry, 2001). 이를 가중치는 해당 지식의 결합 성향에 따라 유사도나 정확도 등으로 선택적 의미 변환할 수 있다.

셋째, 지식을 상황에 의해 생성되는 (Kisling, 2000), 즉 시·공간적인 요인, 환경적인 요인, 개인적인 성향 등 여러 변수에 의해 변화 가능한 가변성이 가지고 있는 변량으로 규정할 수 있으며, 따라서 학습에 의해 연결 가중치의 조정되고, 지식 사이에 결합 및 절단 현상이 발생하여 중심개념이 생성되며 (Devaney, 1997), 이 중심개념을 중심으로 군집화(clustering)된다. 군집화된 지식결합체는 특정 영역의 지식을 표상할 수 있는 객체로서의 역할을 수행할 수 있다.

넷째, 지식에서의 가중치는 관성을 가져야

한다(조형희, 1998). 지식은 적당한 맥락 속에서 만들어 지는데(강남형, 2001), 이는 기존의 지식에 새로운 지식이 결합하여 기존의 지식을 변형함으로써, 또 다른 새로운 지식을 만들어내며, 이러한 경우, 기존 지식의 성향이나 특성을 어느 정도 유지함을 의미한다. 인간의 지각 활동에도 선입견이 존재하여, 이러한 선입견, 즉 이미 습득되어 정착된 개인의 지식은 어느 정도의 맥락성을 유지하며, 외부에서 이 지식과 배반되는 지식이 습득이 되는 경우, 이에 의하여 새로운 지식의 습득에 영향을 미치기도 한다. 이로 인하여 잘못된 지식의 순간유입으로 인하여 개인의 지식체계가 붕괴하는 것을 방지할 수 있다.

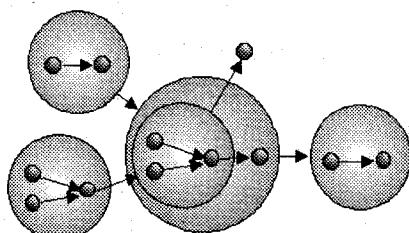
위와 같은 전제를 기저로 하여 교육적 지식 표현에 적합한 신경논리망의 변형 개념을 모델링한다.

X-Neuronet의 표현

지식 공간은 기본적으로 노드와 방향성 있는 결합을 기본 요소로 하여 구성되어지고, 지식 공간내의 지식, 즉 노드는 그들 사이의 결합에 의존하여 독립적 또는 종속적인 형태로 존재한다(Low, 1991). 이에 본 X-Neuronet은 기본적으로 노드와 연결을 이용한 관성을 가지는 방향성 결합체로 표현하며, 다중 결합에 의한 결합체의 구성을 그 결과로서 산출한다.

즉, 본 연구에서 X-Neuronet을 ‘다중 유한 방향성 결합을 허용하는 군집화된 신경논리망’으로 정의한다.

노드는 red, man, 1, is 등 문자열을 기본 단위로 출발하여 방향성 결합에 의해 한번의 결합이 존재하는 단위노드를 형성하며(Quinlan,

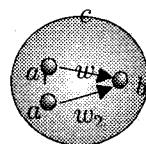


[그림 2] 지식 결합체 모형

1991), 결합의 횟수에 의해 노드의 규모를 변화시킨다. 따라서, 각 노드의 크기는 노드간의 방향성 결합의 횟수에 의해 결정된다.

결합체에 존재하는 가변적 수량은 노드 자체 신뢰도를 의미하는 노드값, 그리고 노드 사이의 연결 가중치이다. 이들 변수는 초기에 확률적 수치로 영역전문가에 의해 부여되지만, 학습과 추론, 그리고 노드의 삽입, 삭제 등에 대해서 지속적으로 보정되는 가변적 성질을 가진다(http://www.aistudy.com/fuzzy/fuzzy_set.htm).

노드는 서로 간의 결합에 대해서 결합체를 확대시켜 나가는데, [그림 2]와 같이, 임의의 특정 노드는 다른 노드와의 다중 결합이 발생한다. 이에 따라 결합체는 이러한 노드를 중심으로 군집화가 되는 경향을 띠게 되며, 이러한 노드는 지식 결합체에서 중심개념의 역할을 수행한다. 물론 결합의 횟수가 많을수록 이 중심개념을 중심으로 한 군집 정도는 강하다.



노드의 군집화는 개념의 전이에 의해 유연성을 제공하여 추론시 발생하는 지식의 희소성(sparsity) 문제를 해결할 기회를 마련한다(안홍섭 외, 1996).

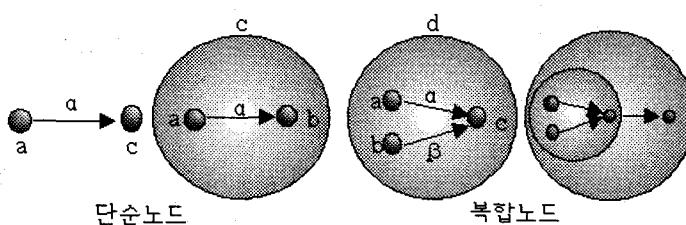
또한 학습이나 영역전문가의 보정, 또는 임계값에 의존하여 노드의 결합과 절단을 실행하며, 보다 발전된 결합체를 구성한다.

노드는 기본적으로 단위노드의 삽입, 또는 노드 사이의 결합에 대해서 더 큰 규모의 복합노드를 형성한다. 노드의 삽입은 영역전문가에 의해 이루어지며, 결합은 삽입, 추론 및 학습의 과정에 형성된다.

결합체의 형성과 안정화 과정은 다음과 같다.

(단계 1) 영역전문가에 의해 노드가 삽입된다. 이 때 노드값, 연결 가중치 등은 영역전문가의 휴리스틱에 의해 임의로 지정되며, 해당 값의 신뢰를 위한 확률적 의미를 지닌다(http://www.aistudy.com/fuzzy/fuzzy_set.htm). 따라서 모든 노드값과 연결가중치는 독립적인 이산화를 변수로 취급한다.

(단계 2) 결합체 내에 존재하는 노드들 사이에 새로운 결합이 시도된다. 새로 유입되는 노드와 기존의 노드 사이에 공통 노드가 존재하면, 두 노드 사이의 공통 노드를 매개로 하여 새로운 복합노드를 구성한다. 다중 결합된



[그림 3] 노드의 분류

노드의 노드값은 산출규칙에 의해 새로운 노드값이나 연결 가중치가 부여된다. 추가되는 노드는 단위노드 형식으로 추가되며, 새로이 추가되는 노드 중에서 기존의 노드에 공통 노드를 가지는 노드는 새로이 노드값과 연결 가중치를 산출한다. 연결가중치와 노드값의 보정시에는 사고의 관성(조형희, 1998)이 적용되며, 이 때 개입되는 노드의 우선 순위는 노드의 생성 시점에 의거한다. 해당 지식 공간 내에서 노드간의 생성 시점이 불분명한 경우에는 유입되는 모든 노드를 동일한 관점에서 처리한다.

(단계 3) 학습에 의해 노드를 안정화한다. 형성된 노드들은 지속적인 학습에 의해 노드값과 연결 가중치를 강화 및 약화시킨다. 또한 임계값 이하로 떨어지는 노드들은 결합의 절단에 의해 노드를 삭제한다.

(단계 4) 안정화된 노드 결합체에서의 노드값은 추론시 노드 활성화를 위한 비교값으로, 결합체 자체는 객체화를 위한 클래스로 제공한다.

X-Neuronet에서의 산출 규칙

본 표현 기법에서는 결합체의 의미해석과 기법의 간소화, 산출 과정의 용이성을 확보하기 위하여 복합노드를 구성하고 있는 노드와 결합에 영향을 미치는 모든 노드값과 연결가중치를 독립적인 변량으로 취급한다.

따라서 생성된 복합노드의 노드값 c 은 내포하는 모든 노드값 a_1, a_2, b 과 연결가중치 w_1, w_2 를 독립변수로 하는 함수로 표현이 가능하다.

$$c = f(a_1, a_2, b, w_1, w_2)$$

이를 일반화하면, 임의의 복합노드의 노드값 val_{node} 은 $val_{node} = f(x_1, x_2, \dots, x_n)$, x_i : 하위 노드값과 연결가중치

로 표현할 수 있다.

하지만 일반적으로 다중결합이 존재하는 복합노드인 경우, 결합을 위해 특정 노드를 공유하기 때문에, 결합을 위해 공유된 목적노드(destination)를 결합의 횟수만큼 분리 변환하여 사용한다. 즉 결합을 위해 노드 b 를 공유하는 하기 때문에 [그림 4]의 두 결합체는 위상적으로 동일하다고 할 수 있으며, 노드값 산출과정에서 후자를 사용한다.

따라서

$$c = f(a_1, a_2, b, w_1, w_2) = f(a_1, a_2, b, b, w_1, w_2)$$

로 표현이 가능하다.

또한, 일반적으로 복합노드의 결합 형태는 다음과 같으며, 이는 결합을 위한 목적노드에 의존하여 구분한다.

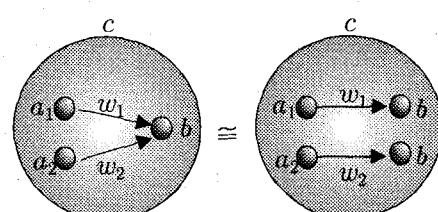
따라서 각 결합에 의한 결과값(val_X, val_Y, val_Z)과 하위 노드값, 연결가중치 간의 관계는 다음과 같이 정의한다.

$$val_X = f(a_2, c, w_2)$$

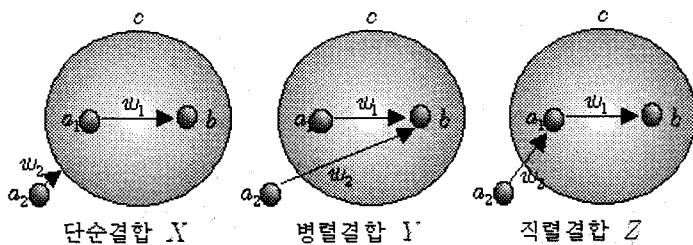
$$val_Y = f(a_1, a_2, b, w_1, w_2)$$

$$val_Z = f(a, a, a, c, d, \beta)$$

n 개의 결합에 의해 생성된 복합노드인 경



[그림 4] 복합노드의 위상적 관계



[그림 5] 복합노드의 구분

$$\dagger, \ val_{node} = f(a_1, \dots, a_n, b_1, \dots, b_n, w_1, \dots, w_n),$$

a_i : 복합노드의 출발(source)노드값,

b_i : 복합노드의 목적노드값

w_i : 복합노드를 구성하는 각각의 연결가중치

로 표현하여 노드값을 산출할 수 있다.

val_{goal} 을 목표값, x_i 는 val_{goal} 에 직접적 영향을 미치는 노드값이나 연결가중치라고 하고, 모든 x_i 가 동일한 비중으로 val_{goal} 에 영향을 미친다고 가정하자.

그러면 일반적인 결정된 목표값은
 $val_{goal} = f(x_1, x_2, \dots, x_n)$ 라고 표현 가능하고,
 주어진 노드값과 연결 가중치를 x_i 로 갖는 이

산확률변수 X (단, $\sum_i^n f(x_i) = 1, f(x_i) = \frac{1}{n}$)
로 취급할 수 있다.

한편, val_{goal} 은 다음과 같은 경향을 가지고 있다고 파악할 수 있다(박하식 외, 1984).

첫째, val_{goal} 은 1차 적률 μ 에 비례한다. 일 반적으로 노드값과 연결 가중치의 값이 증가하면 val_{goal} 도 증가한다.

둘째, 대부분 높은 노드값과 연결 가중치를 가지고 있다 하더라도 어느 하나의 변량이 현저히 낮은 것이라 한다면, 전체적으로 노드값

을 믿을 수 없기 때문에, val_{goal} 은 2차 중심적
률 σ 에 반비례한다.

셋째, val_{goal} 은 3차 중심적률 γ 의 부호에 영향을 받는다. 즉, $\gamma > 0$ 이면 val_{goal} 은 감소하고, $\gamma < 0$ 이면 val_{goal} 은 증가한다.

즉, 주어진 $\{x_i\}_{i=1,\dots,n}$ 에 의해 결정된 μ 와 해당 복합노드에서의 μ 의 가중비을 w_{tend} 에 따라 $val_{...}$ 가 결정된다.

여기에서, σ 와 γ 가 변량의 산포 및 경향성을 나타내는 영향을 미친다고 할 때,

$$\omega_{tend} = \frac{1}{\mu} \exp(\gamma) \sqrt{\sum_i^n (x_i - \mu)^2 f(x_i)},$$

$$\mu = \sum_i^n x_i f(x_i), \quad \gamma = \frac{E(|X - \mu|^3)}{\sigma^3}$$

따라서

$$val_{goal} = f^*(w_{tend})\mu,$$

$$f^* = \frac{3}{2} - f_{sigmoid}(w_{tend})$$

라 정의할 수 있다.

관성의 적용

복합노드에서 새로운 노드가 유입되는 경우
나 노드 사이의 우선순위가 명백한 경우에는
이전의 노드가 어느 정도의 비중을 갖는 관성

이 존재한다(조형희, 1998). 이는 사건 A가 발생하고, 사건 B가 발생하는 것과 사건 B가 발생한 다음 사건 A가 발생하는 것은 개념적으로 같을 수 없다는 것을 전제로 한다(박한식, 1984).

임의의 두 노드값 α, β 가 있고, 노드값 α 가 우선순위를 갖는 관성 결합을 한다고 가정하자.

또한 노드간의 거리는 Δw , 관성을 k 라고 하면, $k \geq 1$, $\Delta w = |\beta - \alpha|$ 이다.

또한, [그림 6]에서 왼쪽 최하단을 원점으로 하는 좌표평면을 가정하면,

표시된 직선은

$$f(x) = \frac{\Delta w}{\Delta w(1+k)}x + \alpha = \frac{1}{(1+k)}x + \alpha$$

이고,

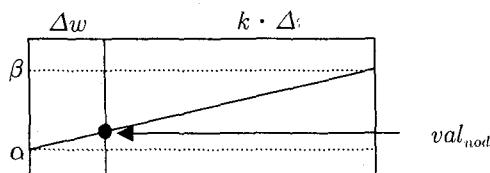
여기에서 결합에 의한 보정값은 $x = \Delta w$ 인 경우이므로

$$f(\Delta w) = \frac{1}{(1+k)}\Delta w + \alpha \text{ 이다.}$$

즉, 보정값 val_{node} 은 관성을 k 와 비례함을 알 수 있다.

여기에서 $k=1$ 인 경우는 $f(\Delta w) = \frac{1}{2}\Delta w + \alpha$, 즉, 관성이 전혀 없는 상태를 의미한다.

관성을 k 는 교수내용지식에서의 학습자의 성향이나 성격, 고집, 선입견 등 학습자가 자



[그림 6] 관성에 의한 노드의 결합

신의 기준의 지식을 유지하려는 개인적 성향을 정량화한 측도로 사용가능하다. 이를 역으로 적용하면, 학습자에 의해 학습된 지식결합체에서 각 노드사이의 가중치를 비교하여 k 값을 구할 수 있고, 이를 바탕으로 학습자 개인 성향 파악이 가능하다.

연산자(Operator)

본 표현기법에서는 노드의 결합 처리와 복합노드의 표현의 적정성을 유지하기 위해 기준의 신경논리망에서 제공하는 기본적인 연산자(Henry, 2001)를 변형하여 적용한다. 연산 처리 후에는 보정된 노드값을 포함하여 연결 상태 모두를 하나의 노드에 매핑한다. 즉 노드가 논리연산자에 결합된 상태만으로도 하나의 소규모 노드 결합체를 형성한다.

각 연산자와 연산식은 그림 7과 같다.

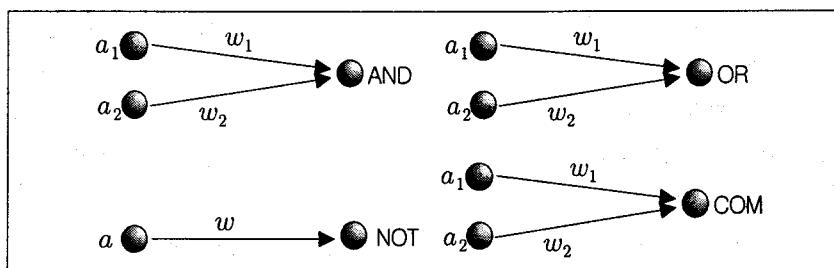
AND연산은 다중 조건을 동시에 만족해야 하므로 AND연산에 의해 새로 생성되는 보정값은 논리적으로 감소한다. 하지만, 신뢰도가 높은 노드들로 이루어진 AND연산에서는 보정값이 상향 조정되어야 함이 명백하다. 따라서 AND연산을 다음과 같이 정의한다.

$$a_1 \wedge a_2 = 1 - \exp(-2\mu^* \ln 2),$$

$$\mu^* = E[a_i w_i] \mid i=1,2$$

OR연산은 다중 조건 중 하나만 만족해도 되므로 OR연산에 의해 새로 생성되는 보정값은 논리적으로 증가한다. 하지만, 신뢰도가 낮은 노드끼리의 결합으로 생성된 노드의 신뢰도가 높다는 것은 논리적으로 모순이다. 따라서 OR연산을 다음과 같이 정의한다.

$$a_1 \vee a_2 = 1 - \exp(-\mu^* \ln 2),$$



[그림 7] 기본 연산자

$$\mu^* = E[a_i w_i] \mid_{i=1,2}$$

NOT연산은 노드값을 보수화하여 다음과 같이 정의한다.

$$\sim a = 1 - aw$$

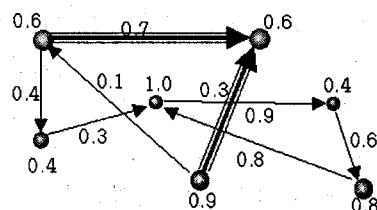
COM연산은 두 노드의 단순결합으로 다음과 같이 정의한다.

$$a_1 \odot a_2 = E[a_i w_i] \mid_{i=1,2}$$

전파 규칙

주어진 결합체에서 조건에 적합한 결론을 얻기 위해서는 필요한 노드, 즉 경로를 활성화해야 하며, 이를 위해 노드값의 전파규칙이 필요하다(이현주, 1996). [그림 8]과 같이 노드값 전파의 모형을 구성하며, 전파규칙은 다음과 같다.

(단계1) 안정화된 결합체를 근거로 보정된 노드값을 활성화의 기준값으로 사용한다.



[그림 8] 임계값이 0.6인 경우

(단계2) 임계값(θ)를 결정한다.

$\theta = -1 - \exp(-n)$, n 은 결합체를 구성하는 단위노드 수

(단계3) 임계값보다 큰 노드값을 가지는 노드들을 활성화한다.

(단계4) 활성화된 노드가 없으면 임계값을 하향 조정한다.

(단계5) (단계3)으로 간다.

네트워크의 안정화 : 학습

교수-학습 활동에서는 교수자 지식베이스에 의한 참조나, 학습자 지식베이스와의 대화의 결과의 형태로 목표값, 즉 네트워크의 학습을 위한 근거가 입력된다. 목표값과 실제 출력값 사이에는 오차가 발생하는 것을 가정한다면, 이 때 발생하는 오차가 한계 범위 안에 존재 할 때까지 각각의 노드값과 연결 가중치를 보정한다. 값의 보정은 출력 노드와 직접적으로 연결되는 1차 결합노드로부터 시작하여 원거리 노드로 확대하여 역보정한다.

가중치 보정을 위한 다른 근거로서 교수자 지식베이스에서는 교수자와의 대화의 결과를 채택 가능하며, 학습자 지식베이스에서는 소유 학습자와의 대화 결과 및 교수자 지식베이

스와의 대화 결과를 채택 가능하다.

학습 과정은 다음과 같이 역전파(back propagation) 학습 알고리즘을 변형하여 적용한다(김대수, 1992).

(단계1) 오차의 한계치(δ)를 결정한다.

(단계2) 목표값(val_{goal})을 설정한다.

(단계3) 목표값(val_{goal})에 직접적으로 영향을 미치는 노드들을 모두 선택한다.

(단계4) 선택되어진 모든 노드의 노드값과 연결 가중치를 이용하여 전체 노드값(val_{est})을 산출한다.

$$val_{est} = f^*(w_{tend})\mu$$

(단계5) val_{goal} 과의 오차(err)를 산출한다.

$$err = val_{est} - val_{goal}$$

(단계6) 오차가 한계치를 초과한 경우 ($\delta < err$)에는 값과 오차를 고려하여 노드값과 연결 가중치를 보정한다. 단, 허용 범위안의 오차가 발생한 경우, (단계8)로 간다.

$$x_i^* = \left(\frac{\sum_i x_i - err \cdot n}{\sum_i x_i} \right) x_i$$

(단계7) 보정된 노드값과 연결 가중치를 이용하여 전체 노드값(val_{est})을 계산한다. (단계5)로 간다.

(단계8) 이전의 과정에서 선택되었던 각각의 1차 노드를 보정한다. 이 때 val_{goal} 은 해당 1차 노드의 노드값이다. (단계4)에서 (단계7)까지의 과정을 반복한다.

(단계9) 1차 노드값 보정 후, 각 하위노드의 소스노드가 단위노드가 될 때까지 값 보정을 반복한다.

실험 검증

본 표현기법에 의해 교수내용지식 표현이 가능하지만, 그 개발 목적과의 부합정도를 살펴보기 위하여 다음과 같은 사항에서 타당도 검증이 필요하다.

첫째, 주어지는 목표값에 대하여 가중치가 역동적으로 변하는가이며,

둘째, 학습된 지식베이스는 학습자 개인에게 적용되도록 유의미하게 차별화되는가이며,

셋째, 임의의 노드 첨삭에 따라 추론 경로와 가중치가 역동적으로 변경되는가이다.

따라서 본 X-Neuronet의 검증을 위해 Visual C++6.0으로 실행모듈 구현하고, 영역전문가에 의해 작성된 지식베이스를 기반으로 실험을 실시하여 그 결과를 분석하였다.

검증 과정

(단계 1) 중학교 과학 교과를 대상으로 임의 개의 결합없는(unlinked) 단순노드를 생성하고 노드값(%)을 임의 할당한다. 다음은 노드의 구조체를 표현한 것이다.

```
< Structure of Simple Node >
struct Simple_Node{
    int idx_node;           // 노드번호
    char* element;          // 기본요소
    int node_value;         // 노드값
};
```

```
< Structure of Complex Node >
struct Complex_Node{
    int idx_node;           // 노드번호
    int idx_src_node;       // 출발노드
    int idx_dest_node;      // 목적노드
    int linked_weight;      // 연결가중
};
```

< 목표값 도달 가능한 경로 탐색 알고리즘 >

```

검색트리, 테이블 정의; // 테이블에는 노드번호가 탑재
테이블의 모든 값을 0으로 초기화;
목표값(goal:root) 설정;
level(depth) = m 설정;
(서브노드)(i)|i = 1, ..., n = 검색(목표값);
while ((서브노드의 출발지노드가 복합노드일 때)&&(level(i) m보다 작을 때)) {
    (서브노드)(i) 접근;
    검색((서브노드)(i));
    검색트리에 저장;
}

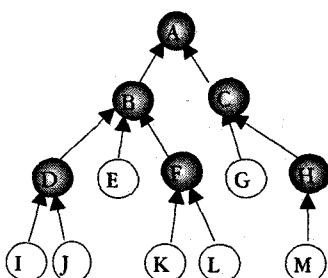
각각의 terminal node(i)에서 root에 이르는 path를 Node Table의 (i)행에 저장;
검색(목표값) {
    for (검색노드의 개수가 total_node보다 적은 동안)
        if(목표값을 목적지노드로 갖는 노드가 있으면 {
            노드와 출발지노드를 목표값의 서브노드로 저장; // 트리구조
        }
    }
}
}

```

(단계 2) 순서에 의존하여 임의의 두 개의 노드를 선택하여 복합노드를 생성한다. 이 때, 선택에 의해 노드화된 복합노드는 다시 선택 대상 노드로 취급된다.

(단계 3) 목표값을 임의 결정한다.

(단계 4) 지정된 목표값에 도달 가능한 모든 경로를 탐색한다.



[그림 9] 검색트리

[표 1] Node Table

	level 1	level 2	level 3	level 4
path 1	A	B	D	I
path 2	A	B	D	J
path 3	A	B	E	
path 4	A	B	F	K
path 5	A	B	F	L
path 6	A	C	G	
path 7	A	C	H	M

목표값(root)이 A인 경우에는 다음과 같이 트리와 테이블이 구성된다(Table[1]).

(단계 5) Node Table에서 각 path의 노드값을 산출하고 노드값에 의해서 내림차순 정렬한다.

(단계 6) 지식베이스 사용자와 대화를 한다.

즉, 사용자가 출발노드와 목적노드의 노드값과 연결가중치를 수정한다.

(단계 7) 학습 규칙에 의해 네트워크를 안정화한다. 안정화된 지식 구조를 Table[II]에 저장한다.

(단계 8) 안정화된 전체 노드 구조체로부터
임의의 단위노드를 삭제한다.

이 상태에서 학습을 하여 네트워크를 안정화하고, 지식 구조를 Table[III]에 저장한다.

(단계 9) 각각의 Table[i]에 대하여 각각 (단계3)에서 (단계5)의 과정을 반복하고, 결과를 획득한다.

(단계 10) 획득한 결과를 분석한다. 특히 지식베이스의 적응성 검증을 위해서는 별도로 생성되고 학습된 다른 결합체의 노드값과 연결가중치를 비교한다. 두 결합체 사이의 유의미한 차이를 검증하기 위해 직접 차 계산법에 의한 t검증을 사용한다(김정환, 2003).

검증 결과

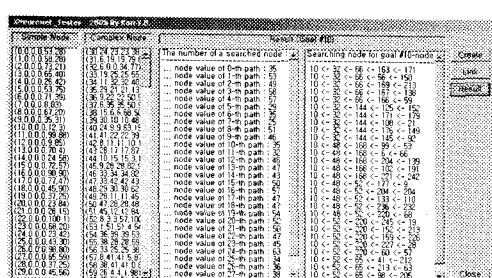
본 실험에서 30개의 단위노드와 220개의 복합노드를 무작위 생성[그림 10]하여, 임의로 결정한 목표값을 추적할 수 있는 하위노드 (Level 5)까지의 검색 가능한 경로를 획득하여

표현학 방향성 결합체를 구성하였다.

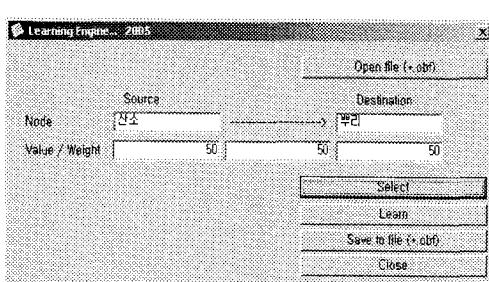
실험에 의해 검색된 경로는 Level[2]에서 회
소성 문제가 발생하지 않는 한, 다양한 경로
와 가중치를 갖는다. 입력된 단순노드의 개수
를 고려할 때, [그림 12]에서 볼 수 있듯이 각
레벨에서 획득할 수 있는 노드수와 임의 선택
한 노드를 설명할 수 있는 하위노드(subnode)수
는 충분하다.

이는 목표값에 도달할 수 있는 다양한 지식의 흐름, 즉 추론 과정 설명을 위한 다양한 경로를 제공하여 교수·학습활동의 유연성을 확보케 한다.

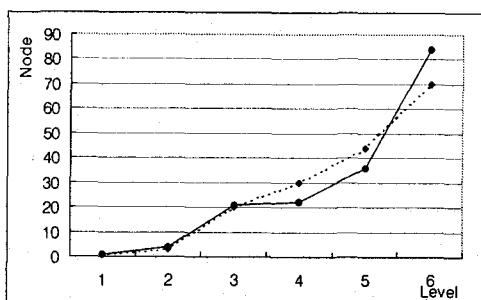
[그림 13]은 임의의 가중치가 1.00인 노드를 입력하고, 이를 공리노드로 학습을 한 후의 각 노드의 가중치 변화 정도를 나타내며, [그림 14]는 임의 노드를 삭제하고 생성된 지식 결합체를 학습시킨 후, 각각의 노드 가중치의 변화량을 도식화한 것이다. 지식 결합체를 형성하고 있는 하나의 임의노드 삭제, 또는 공리노드의 삽입 등의 이벤트를 발생시킨 후, 지식결합체를 학습[그림 11]을 시키면, 노드값이나 연결가중치가 역동적으로 반응을 보인다. 이는 교수-학습 활동에 관여하는 변인 중 한 요인의 변화에 다른 요소들이 능동적으로 반응할 수 있는 교수내용지식 구조의 표현에 대



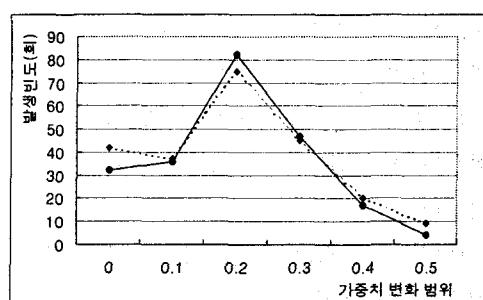
[그림 10] 노드생성 결과



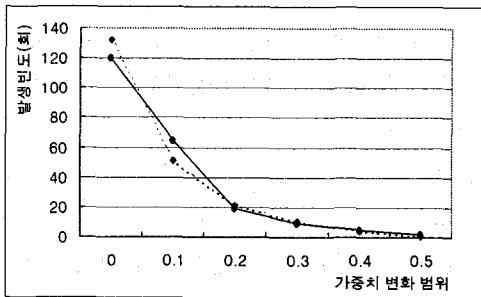
[그림 11] 결합체의 학습 모듈



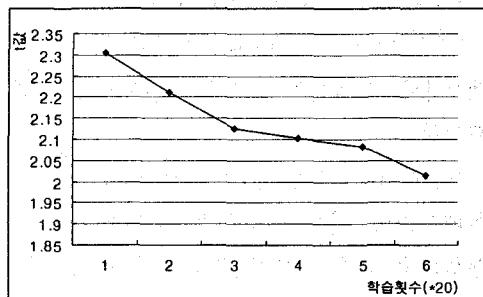
[그림 12] 각 Level에서 획득된 노드수



[그림 13] 학습 후 가중치 변화



[그림 14] 임의노드 삭제 후 가중치 변화



[그림 15] 학습횟수에 따른 t값의 변화

한 가능성을 제고한다.

또한 [그림 15]는 상이하게 형성된 두 지식 결합체에 대한 학습 횟수와 그에 따른 t 값을 도식화한 것으로 전체적으로 t 값은 해당 자유도에서 t_{cr} 값을 초과하여 임의의 학습된 두 결합체는 유의미한 차이가 있음을 알 수 있다. 따라서 형성된 지식결합체를 초기화하여 객체로 사용하는 경우 다수의 학습자 개인에게 적응되는 지식베이스를 구축할 기회를 제공한다.

이상의 실험 결과를 살펴보면, 본 기법은 교수내용지식과 같이, 가변성과 영역별 경계가 뚜렷한 지식표현에 효과적으로 적용되고, 개별적인 지식베이스를 구축하는 데에 수월성을 제공하리라고 판단하기에 무리가 없다.

결 론

본 연구에서는 신경논리망의 논리추론과 가중치의 가변성, 그리고 인지구조에서 노드의 위상적 불변성을 근거로, 교수내용지식과 객체지향 개념을 포함하는 X-Neuronet을 제안하고, 이 기법에 대한 타당성을 검증하였다.

X-Neuronet은 표현의 대상이 되는 지식을 관성과 가변성을 가지는 방향성 결합체로 정의하고, 표현을 위한 기본 개념, 노드의 처리와 연산을 위한 논리연산자, 노드값과 가중치의 결정, 노드활성을 위한 전파 규칙, 학습 알고리즘 등을 제공한다.

본 표현기법은 신경논리망의 변형이라 할 수 있으나, 기존의 신경논리망과는 다른 크기의 노드 결합 보장, 자기 학습에 의한 군집화,

군집화된 결합체의 객체화, 객체화를 통한 지식의 용이한 이동성, 결합체의 개별 성장 가능성, 다양한 경로의 도출 등의 차이점을 가진다.

따라서 X-Neuronet은 지식의 군집화에 의한 맥락의 기술, 다양한 경로의 제공이라는 측면에서 교수내용지식의 표현에 적합하며, 또한 구축된 결합체를 객체화하여 동일한 프레임을 가지는 소규모 지식베이스 객체를 생성하고, 이 객체간의 통신 및 대화에 의하여 각각 개별화된 객체로 성장하여 적용적 지식베이스 구축에 수월성을 제공한다. 또한, 교수내용지식의 적용이 필수적인 ITS에의 지식 표현에 효율적인 기법을 제공하리라 추측하기에 무리가 없다.

본 기법의 타당도 검증과 적용 가능성이 긍정적이라 하더라도, 본 망을 구성하는 하위 항목에 대한 심층적인 연구와 결점에 대한 보완이 지속적으로 이루어져야 하고, 또한 실제로 특정 교과가 적용한 ITS가 구축되어야 한다. 특히 실험과정에서 발생한 희소성 문제를 해결하기 위해 의미의 내포와 논리를 통한 노드간 포함 관계, 또는 의미 전환 등 유사성에 관한 연구, 독립변인을 학습자로 하는 학습자 지식 객체 모델링에 관한 연구 등에 대한 지속적인 연구가 필요하다.

참고문헌

- 강남형 (2001). 개인의식 창출과정과 이에 영향을 주는 요인. 이화여자대학교 대학원. p22.
- 강창동, 채선희 (2001). 학교교육 지원을 위한 사이버 교육 방안에 관한 연구 I, 한국교육과정평가원.

- 김대수 (1992). 신경망 이론과 응용(1). 하이테크 정보. pp91-142.
- 김석우, 김대현 (2003). 교육과정 및 교육평가. 서울: 학지사. p151.
- 김성식 (1996). 인공지능 기법, 흥릉과학출판사. pp457-474.
- 김정환 (2003). 교육연구 및 통계방법, 원미사, pp437-456.
- 민 윤 (1999). 사회과에서 교수내용지식의 가능성과 한계. 사회과교육 32호. pp413-414.
- 백영균 (1991). 지적교수시스템 설계를 위한 지식표현의 기법에 관한 연구. 교육공학 연구 제7권 1호. pp 87-110.
- 박한식, 이강섭 역 (1984). 수리통계학, 교육연구사, pp90-95.
- 안홍섭, 노희섭 (1996). 유연한 추론을 위한 하이브리드 지식표현 구조. 한국인지과학회 논문지 9권 3호.
- 이돈희 외 (1997). 사회과 교과학 연구. 한국교육개발원. pp 1-17.
- 이정모 (1996) 연결주의: 이론적 특성과 문제점. 서울: 성원사 p117.
- 이현주, 김재호 (1996). 신경논리망 기반의 퍼지추론 네트워크와 탐색전략. 한국정보리학회 논문지 3권 5호. pp1138-1146.
- 임진호 (2003). 학습객체 기반의 콘텐츠 제작 방법론 e-러닝 콘텐츠 표준화 포럼 2003 세미나 발표자료.
- 조형희 외 역 (1998), 트리즈, 현실과미래.
- Bower, G. (1981). Mood and memory. American Psychologist, 36: 129-148.
- B. T. Low, H. C. Lui, A. H. Tan, H. H. Teh. (1991). Connectionist Expert System with Adaptive Learning Capability. IEEE Transactions on Knowledge and Data Engineering, Vol

- 3.2. 200-207.
- Chia H W-K and C-L Tan, (2004). Association-based evolution of comprehensive neural logic networks. GECCO 2004, 26-30 June 2004. Seattle, Washington, USA.
- Cochran, Kathryn F. (1993). Pedagogical content Knowing: An Integrative Model for Teacher Preparation. *Journal of Teacher Education*. September-October Vol. 44. No.4. p265.
- Gudmundsdottir, S. (1988). Pedagogical Content Knowldge: Expert/Novice Companion in social Studies. Annul Meeting of American Educational Association in April.
- Henry W. C., Chew L. T. (2001). Neural Logic Network Learning using Genetic Programming. International Journal of Computational Intelligence and Applications, Vol. 1, No. 4 (2001) 357-368.
- Hyman, R. (1973). Approaches in Curriculum. New Jersey: Prentice-Hall.
- Jonassen, D. H. (1989). Instructional Designs for Microcomputer Courseware, Englewood Cliffs, New Jersey: ET Publications.
- Kisling, E. L & Kalman, H. K. (2000). Potential of knowledge management in instructional technology. 2000AECT annual convention.
- Livingston, Carol & Borko, Hilda. (1989). Expert Novice Difference in Teaching: A Cognitive Analysis and Implications for Teacher Education. *Journal of Teacher Education*. July-August. p.37.
- Mal-Rey Lee. (2001). Fuzzy Inference Network and Search Strategy using Neural Logic Network. *멀티미디어학회 논문지* 4(2). pp189-196.
- Mandler, G. (1967). Organization and memory, In K.W. Spence & J. T. Spence(Eds.). *The psychology of learning and motivation* (Vol. 1). New York: Academic Press.
- Mark Devaney, Ashwin Ram (1997), "Efficient Feature Selection in Conceptual Clustering", Machine Learning: Proceeding of the Fourteenth International Conference, Nashville.
- Quinlan, P. (1991). Connecitionism and psychology: A psychological perspective on new connectionist research. Chicago: Chicago U. Press.
- Rafael A. Faraco, Marta C. Rosatelli, Fernando A. O. Gauthier, (2004). "Adaptivity in a Learning Companion System", Forth IEEE International Conference on advanced Learning Technologies(ICALT'04) pp151-155.
- Shulman, L. S. (1986). Those Who Understand: Knowledge Growth in Theaching. *Educational Researcher*. 15(2). p.8.
- Wiley, D. (2002). Connecting learning objects to instructional design theory: A definition, a metaphor, and a taxonomy in D W Wiley (Ed) *The instructional use of learning objects* Bloomington, IN Agency for Instructional Technology Association for Educational Communications and Technology.
- Minsky[1]: http://www.aistudy.com/expert/knowledge_representation.htm
http://www.aistudy.com/expert/knowledge_representation.htm
http://www.aistudy.com/fuzzy/fuzzy_set.htm

1 차원고점수: 2005. 9. 14

2 차원고점수: 2005. 11. 11

최종게제승인: 2005. 11. 14