

연결주의에 기반한 학습자 특성의 정량화 기법

김 용 범[†] · 김 영 식^{††}

요 약

개별화 학습은 단지 하나의 교수·학습 방법으로서의 의미가 아니라 인식의 보편화되어 교실 수업뿐만 아니라, 성인 교육, 기업 교육 등 다양한 교수·학습 상황에서 관심을 끌어들였다. 한편 효과적인 개별화 학습은 학습자 특성에 대한 정확한 분석 및 측정이 필수적으로 요구되나, 학습자 특성에 대한 개념과 범주가 다양하고 광범위하여 그에 대한 계량적인 기술이 어렵다. 이에 본 연구에서는 학습자 특성을 인지구조와 인지양식으로 제한하였다. 또한 학습자 특성을 연결주의적 관점에서 기술하고 이를 기반으로 하여 학습자 특성의 정량화 기법을 제안하며 그에 대한 타당성을 검증하였다. 본 연구에서의 학습자 인지구조는 기존에 연구된 학습자 인지구조 객체를 간소화하였고 인지양식은 학습자 인지의 지식관성력으로 축소하여 기술하였다.

키워드 : 연결주의, 학습자 특성, 정량화 기법

A Quantification Method of Learner's Characteristic based on the Connectionism

Yongbeom Kim[†] · Yungsik Kim^{††}

ABSTRACT

It seems reasonable to assume that the individualized learning means more than simple teaching-learning method, so the instructional method has attracted a fair amount of attention not only in classroom, but also in the field of a adult education, cooperate education, and so on. In order to have an effect on individualized learning, we need to analyze and measure the learner's characteristic. However it is difficult to represent in quantified form because the conception and category of learner's characteristic is various and extensive. Therefore, in this paper, we propose a quantification method of learner's characteristic, which is limited to learner's cognitive structure and style, and is represented in the light of connectionism, verify the validity. The learner's cognitive structure in this paper was represented, which simplified the learner's cognitive structure. Additionally, the cognitive style in this paper was limited to inertia of knowledge for learner's cognition.

Keywords : Connectionism, Learner's Characteristic, Quantification Method

1. 서 론

교육은 관점에 따라 다양하게 정의(a definition of education) 되어 확고하게 정립된 표현으로 정의(the definition of education)할 수는 없으나[15], 교육의 기본 범주에 지식의 전달, 즉 '가르치는 것(教授 : teaching)'을 포함하여야 한다는 것에는 이견이 없다[8]. 또한 이 '교수(teaching)'라는 개념은 교수목표, 교과내용 그리고 교수방법을 고려함으로써 구체화되고[20], 적용되는 교육방법은 정해진 학습 내용을

효과적으로 전달하기 위해서 선정된 학습요소가 어떠한 방법으로 투입되어야 하는가를 고려하여 선택되어진다는 것, 또한 일반적으로 의견을 같이 한다. 이러한 맥락에서 현대 교육의 효과적인 교수·학습 전략으로 '개별화 학습'이 중요한 패러다임으로 자리잡고 있는데, 이는 교실 수업뿐만 아니라, 상업용 교육, 성인 및 기업 교육 그리고 컴퓨터를 매개로 하는 교육 등 다양한 교수·학습 상황에서 확대 적용되고 있는 실정이다[5].

개별화는 학습자 개인이 가지고 있는 성취의 잠재력을 적절하게 발전시키기 위한 개념으로 효과적인 개별화는 학습자 특성에 대한 분석 및 개인차에 대한 정확한 측정과 진단을 필수적으로 요구하고, 이러한 개별 학습자의 상태에 근거하는 학습자 특성에 따른 개별적인 처방은 교육적 기회와

[†] 정 회 원 : 충남 금산여자고등학교 교사

^{††} 정 회 원 : 한국교원대학교 컴퓨터교육과 교수

논문접수 : 2008년 5월 7일

수정일 : 1차 2008년 8월 12일, 2차 2008년 9월 22일

심사완료 : 2008년 9월 30일

배려를 포함하여 단순한 교수·학습 전략 이상의 의미를 갖는다고 할 수 있다[5]. 한편, 개별화 학습의 중심 주제는 개인차 변인에 입각한 적응적 학습 환경을 어떻게 제공하느냐와 학습에 영향을 미치는 개인차 변인을 개인 학습자들에게 어떻게 적용시키느냐로 대별할 수 있다. 이 때의 개인차 변인, 즉 학습자 특성에 대한 개념은 관점에 따라 다양하나, 학습자의 인지(cognition), 적성 변인, 선수지식, 인성적 변인 등에 대한 개인차로 규정하는 것이 일반적인 경향이다[1][14].

하지만 학습자 특성은 각 변인의 다양성과 복잡성으로 인하여 그에 대한 명시적인 기술(description), 즉 구별 가능한 정량화가 어려워 교수·학습과정에서의 적절한 투입을 위한 개별 학습자의 특성에 대한 명확한 분석 기법은 주요 연구 주제로 다루어져 왔다. 이에 학습자 특성의 명시화 및 적용의 용이성 확보를 위하여 관심 범주를 인지구조와 인지양식으로 제한하고 개별 학습자의 특성을 인지에 기반하여 정량화하는 방안은 충분한 연구의 가치가 있다고 할 수 있다.

이에 본 연구에서는 학습자의 인지구조와 인지양식으로 제한한 학습자 특성을 연결주의적 관점에서 표현하고 이에 기반하여 학습자 특성의 정량화 기법을 제안하였다. 또한 이 기법에 대한 타당성을 검증하고 적용 가능성을 모색하였다.

학습자 인지에 기반한 학습자 특성의 정량화 방안은, 학습자 특성이 수량적 산출이 가능한 형태로의 표현이 가능하다는 것과 제안된 표현 구조는 실제 학습자의 특성과 밀접한 상관관계를 유지한다는 것을 전제한다. 본 연구에서의 학습자 인지구조는 기존의 학습자 인지구조 객체[2]를 간소화하여 표상하고 인지양식은 학습자 인지의 관성적 성향, 즉 지식관성력으로 축소하여 규명하였다.

2. 이론적 기초

2.1. 학습자 특성

학습자는 학습에 의하여 나름대로의 독특한 이해 체계를 형성하고, 그 이해 체계를 구성하기 위한 능력 또한 상이하여 정해진 내용을 동일한 시간과 교수 방법에 의해 학습을 하더라도 개별 학습자에게 형성된 이해 체계와 양은 다양할 수밖에 없다[14].

이에 개별화된 학습은 학습자의 특성에 대한 분석에서 출발하고, 분석되어 획득된 개별 학습자의 개인차에 대한 적절한 적용으로 구현되고 학습자의 개인차에 대한 정확한 진단 및 측정은 교육의 개별화를 위한 전제 조건이라 할 수 있다[1].

또한 이 개별화 학습은 개별 학습자의 특성에 근거하는 개별적인 처방이 주어진다라는 점에서 교육적 기회와 배려의 의미를 포함하고 있어[5] 현대 교육에 있어서 긍정적인 교수-학습이 주요 패러다임으로 자리잡고 있다.

한편 학습자 특성은 일반적으로 학습자의 개인차 변인을 의미하나, 관점에 따라 다양하게 개념 및 범주를 규정하고 있다.

호재숙(1994)은 학습자 특성을 정신능력 변인, 인지양식

변인, 인성 변인으로 분류하고 정신 능력은 지능, 선수 학습, 언어 능력, 비언어적 추리력, 학문과 관련된 적성, 주의 집중력, 공간 능력, 학업 성취로, 인성은 동기적인 변인인 근심, 성취 욕구, 자극 탐구 동기로, 기타 변인으로 외상성이나 일반적 활동성, 집중성, 정서적 안정성 등으로 정의하였다[10].

Janassen과 Grabowsky(1993)는 학습자들은 정보를 처리하고 의미를 구성하고 이를 새로운 상황에 적용하는 과정에서 각기 다른 지식, 태도, 선호도를 가진다고 언급하면서 학교 과제 또는 실제생활과 관련된 학습과제에 따라 학습자가 사용하는 능력과 기술이 달라지며, 이러한 학습자의 특성은 과제수행 결과에 영향을 준다고 하였다[14].

김형수 등(2006)은 인지적 특성은 학습자의 독립적 학습 활동을 통해 학업성취도를 결정하고 이와 같이 학습전략에 대한 직접적인 영향을 주는 요인을 학습자 특성으로 규정하고 학업능력, 상위인지활용능력, 동기 수준 등을 범주에 포함하였다[3].

Dixon(2000)은 온라인 학습공동체에서의 학습자 특성으로 학습자의 개인과제와 협력과제 수행 경험, 구성원으로서 역할 경험, 학습자의 지식수준이 학습 수행에 영향을 미치게 된다고 하였다[13].

또한 이옥화(2006)과 정혜정 등(2008)은 신세대 학습자 특성에서 사이버 커뮤니티이션이 차지하는 비중과 상호작용의 유형과의 관계에 대하여 언급하였다[7][9].

이상의 학습자 특성에 대한 범주를 살펴보면 시기적으로 지능과 선행 지식 등 능력적 특성에서 점차 흥미, 태도, 학습 습관, 인지 양식, 자아 개념 등 비능력적 특성도 중요시 하며, 또한 네트워크 환경에서의 학습자 특성도 점차 고려하는 경향을 가지고 있다.

이러한 특성의 변화를 포함하여 일반적으로 학습과 개념 변화에 가장 영향을 끼치는 변인으로 지능, 인지구조, 인지양식, 성격 등을 우선시하며[4] 더 세분화하여 다양한 학습자 특성의 성격 규명에서 공통적으로 추출할 수 있는 주요 요소가 학습자의 학습된 지식 상태인 인지(cognition)와 정보를 지각하고 처리하는 개인적인 유형인 인지양식(cognitive style)[19]이라는 점에도 대부분의 학자들이 의견을 같이 한다.

이에 학습자 특성의 범주를 인지구조와 인지양식으로 제한하고 학습자 특성에 대한 정량적 분석을 통한 명확한 적용 가능성 모색에 관한 연구는 충분한 가치가 있다고 할 수 있다.

한편 개별 학습자를 동일한 분석 방법으로 정량화하기 위해 불변 요소와 가변 요소의 공존은 필수적이다. 이에 연결주의(connectionism) 관점에서 의미망적인 위상구조와 신경망적인 산출 규칙을 포함하는 학습자 특성의 표상 기법은 충분히 타당하며, 이에 본 연구에서 인지구조는 학습자에 의해 구성된 지식의 방향성 위상구조로, 학습자의 인지양식은 계량화할 수 있는 대상 도메인에 대한 지식관성력으로 축소하고자 한다.

2.2. 연결주의와 확장 신경논리망(extended Neuronet)

인지(cognition)에 대한 연결주의적인 접근은 McCulloch와 Pitts의 형식적 신경모형이 정교화된 형태로 변형된 것이다 [18]. 형식적 신경모형에서는 신경세포들 사이의 신경 연결을 논리에 의해 모형화하여 인간의 두뇌를 신경망(neural network)상의 노드(node)와 노드들 간의 상호작용으로 구현할 수 있다고 보았으나, 신경의 학습 가능성에 대한 한계점을 지니서 인간의 인지(cognition)를 모형화하기에는 부적절한 모형으로 간주되었다. 이러한 연결주의적 신경모형은 세포군집 학습이론, 퍼셉트론(perceptron)체계, 망 활동의 안정, 다층망에 대한 망의 훈련 기법, 비선형적 체계에 대한 수리적인 기술 이론 그리고 컴퓨터에 의해 기술 가능한 병렬분산처리 모형 등의 여러 이론적 개념들의 발전으로 인하여 인지심리학에 중요한 하나의 모형으로 자리 잡았다[18]. 연결주의는 인간의 정보처리 원리를 이해하는 모형으로서 망 구조, 단위 간의 연결 비중, 활성화 패턴에 의한 표현 등을 일반적 체계 특성으로 가지고 있다. 또한 이러한 신경망 정보처리체계에서의 기본 활동은 외부 자극에 상응하는 활성화 패턴을 수리적, 확률적 계산에 의하여 형성하고 조절하는 것이며, 이러한 활동들의 총체를 인지(cognition)로 규정한다[17]. 하지만, 기본적으로 신경망은 특정 지식에 대한 선택(mining)에 관심을 두어 선택된 지식의 과정을 설명하기 위해서는 약점을 가지고 있다. 이에 ACES[11]를 시점으로 신경망에서의 논리추론의 적용에 대한 연구가 지속적으로 이루어졌고, 이를 근거로 등장하게 된 신경논리망의 주요 관심은 추론 네트워크의 구성 등 임의의 특정 요소를 찾는 탐색의 기법에 대한 연구이다 [12]. 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 교육에서의 지식의 의미인 '교수내용지식'의 표현에 있어서는 지식구성요소의 단순 연결 보다는 유의미한 노드의 결합적 형식이 적합하다. 이러한 개념에서 교수내용지식의 표현을 목적으로 하는 X-Neuronet[2]은 연결주의적 관점에서 신경논리망의 논리추론과 가중치의 가변성[12] 그리고 인지구조에서 노드의 위상적 불변성을 기저로 하며, 기본적으로 노드와 연결을 이용한 방향성 결합체로 표현한다. X-Neuronet에서 가변적 수량은 노드 자체 신뢰도를 의미하는 노드값과 노드 사이의 연결 가중치이며 결합체는 학습과 추론, 그리고 노드의 삽입, 삭제 등에 의해서 지속적으로 보정되어진다.

X-Neuronet에서 임의의 복합노드에 대한 노드값 val_{node} 은 $val_{node} = f(x_1, x_2, \dots, x_n)$, x_i : 하위 노드값과 연결가중치로 표현하고, 특정 목표값 val_{goal} 은 모든 x_i 가 동일한 비중으로 val_{goal} 에 영향을 미친다는 가정에서 출발한다. 이 때 확률적 의미를 갖는 x_i 의 경향성에 따라 val_{goal} 은 주어진 $\{x_i\}_{i=1, \dots, n}$ 에 의해 결정된 μ 와 그에 대한 가중비율 w_{tend} 에 따라 val_{goal} 가 결정된다.

따라서

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

$$val_{goal} = \left\{ \frac{3}{2} - f_{sigmoid}(w_{tend}) \right\} \mu \quad (2)$$

이다.

X-Neuronet에 의존하여 형성된 지식 결합체는 교수내용 지식의 개념을 포함할 뿐만 아니라, 교과에서의 학습 단위인 주제별, 단원별 캡슐화가 가능하여 인지구조체를 모형화할 기회를 제공한다. 이 때, 모형화된 인지구조체[2]는 대상도메인의 모든 내용을 포함하는 전체적인 유한 구조의 틀(frame), 구성된 각 노드들 사이의 방향성 연결 그리고 노드와 연결에 각각 주어진 가중치로 구성한다. 대상도메인의 궁극적 목표인 최상위 목적노드를 기저로 하여 이에 포함되는 모든 개념을 이용하여 1차 하위노드를 결정하고, 결정된 하위노드를 재분할하여 2, 3차 하위노드를 반복적으로 산출하여 다층의 방향성 결합체를 구성한다. 인지구조에 존재하는 가변적인 수량은 노드값과 연결 가중치로, 초기값은 영역전문가의 경험과 해당도메인의 결합 구조에 의존하지만, 학습 과정에서 지속적으로 보정되는 가변적인 성질을 가진다. 이러한 학습 과정을 거쳐 학습자에 의해 학습된 학습자 인지구조는 소유자의 지식 상태를 근사적으로 표상하며, 이에 형성된 인지구조는 학습 도달 상태의 파악 및 활용을 위한 근거를 제공한다.

본 연구에서는 X-Neuronet을 적용한 학습자 인지구조 객체 모형[2]의 과정을 간소화하여 학습자 인지구조를 표상하고 이 구조를 학습자 특성의 정량화 근거로 삼는다.

3. 학습자 특성의 정량화 기법

본 연구에서의 학습자 특성은 추출과 정량화가 가능하도록 인지구조와 인지양식으로 제한하였다.

이에 본 연구에서의 학습자 인지구조는 '학습자 인지구조 객체 모형[2]'을 근거로 하여 구성하며 그 과정의 용이성을 확보하기 위하여 학습 요소 추출 및 구조(frame)의 구성 방식을 기존 연구와 차별화하였다.

또한 인지양식은 학습의 과정에서 개별 학습자에 의해 이미 습득된 각각의 단위지식이 어느 정도의 관성을 가지고 새로 유입되는 지식에 관여를 하는가에 관심을 가지며, 이 때 산출되는 변량을 지식관성으로 정의하여 해석한다.

3.1. 인지구조(cognitive structure) 표상의 간소화

학습자 특성의 효과적으로 정량화하기 위해 학습자 특성의 구조적 객체인 학습자 인지구조를 특정 교과 및 단원을 대상으로 실제화하였다. 이 과정에서 기존의 학습자 인지구조 객체 모형[2]에서 요구하는 형식화가 명시적으로 간소화되도록 객체 구성 기법을 재구성하였다.

인지구조의 표상을 위해 선수 행동은 대상 영역에서 유의미한 정도의 문항을 제작하고, 이 문항들을 분석하여 문항

층과 다층의 학습요소층을 결정하는 것이다.

이 때, 제작된 각 문항은 문항 자체가 포함하는 세부 학습요소 및 개념 단위로 분할하여 하위노드 설정을 위한 근거로 사용되며, 제시된 문항과 추출된 하위노드를 유향선으로 결합하여 전체 인지구조 표현을 위한 방향성 그래프의 부분(subset)으로 결정한다.

모든 문항에 대한 반복적인 수행 그리고 직접적으로 관련성이 없는 모든 노드의 결합도 방향성 결합을 취하여 학습자 인지구조의 기본적인 틀(frame)을 구축한다.

(그림 1)과 같이 영역전문가에 의해 제작된 문항(P_1, P_2, \dots, P_n)에서 각 문항에 포함되어 있는 모든 학습요소($P_1\{E_1, E_2, E_3, E_m\}, P_2\{E_2, E_{m-2}, E_{m-1}\}, \dots, P_n\{E_{m-2}, E_{m-1}, E_m\}$)를 추출하여 방향성 그래프로 구성하고, 각 노드 및 연결에는 가중치를 초기화한다. (그림 2)는 제작된 문항을 기반으로 학습요소층을 구성한 위계의 사례이다.

학습요소($E_1, E_2, E_3, \dots, E_m$)의 개수가 m 인 경우, 노드 값 및 연결가중치는 $\beta_i, w_{i|i=1,2,\dots,m} = \frac{1}{m} + 0.50 (m \geq 2)$ 으로 결정하고, 목적노드인 문항(P_1, P_2, \dots, P_n)의 노드값($\alpha_i | i=1,2,\dots,n$)은 true인 1.00으로 설정한다. 또한 노드 간에 직접적 관련성이 없는 경우에도 개념 내포성을 고려하여 방향성을 결정하고 무의미값(meaningless value)으로 연결가중치를 초기화한다.

여기에서 노드값이나 가중치는 0.00에서 1.00까지의 확률적 수치로 표현하며, 이 때 0.00은 false를, 1.00은 true를, 그리고 0.50은 무의미값(meaningless value)를 의미한다.

주어진 문항에 대한 학습자 반응을 정량화하기 위한 노드 값과 가중치의 산출은 가중비율과 역전과 알고리즘을 변형한 X-Neuronet의 산출규칙에 의존한다.


즉, 개별 학습자의 문항 반응에 의해 결정된 문항 노드값의 입력값에 따라 소유자의 인지구조는 개별적으로 학습(self-learning)되어진다.

3.2 인지양식(cognitive style)의 정량화

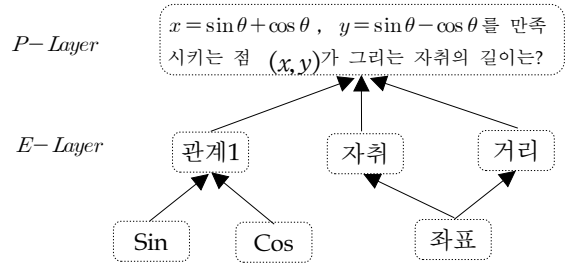
3.2.1 지식 관성률의 개념

본 연구에서의 인지양식은 지식관성으로 제한한다.

이미 형성되어 학습된 특정 지식의 구조가 있고 이와 동일한 구조를 갖으며 진리값이 서로 상이(相異)한 지식이 유



(그림 1) 인지구조의 결정과정



(그림 2) 제작된 문항을 기반으로 한 위계 사례

입되는 경우, 학습된 기존 지식은 새로운 지식의 유입에 따른 해당 지식의 재구성에 일정 수준의 영향을 끼치게 된다.

이는 이미 학습자에 의해 습득된 사전지식, 선입견 또는 인지양식(cognitive style) 등이 새로운 지식의 결합에 관성적 영향을 미친다[4][19]는 것과 맥락을 같이하며, 사건 A가 발생한 후 사건 B가 발생하는 것은 사건 B가 발생한 후 사건 A가 발생하는 것과 개념적으로 같을 수 없다는 것을 전제로 한다.

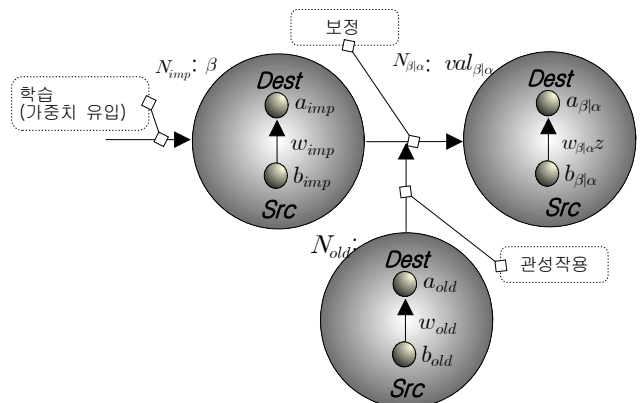
이러한 인간의 사고과정에 있어서의 관성은 일반적으로 인정하나[4], 이에 대한 정량적 분석에 대한 연구는 미비한 상태이다.

따라서 유입되는 새로운 지식에 따른 해당 지식의 가중치 산출은 기존 지식의 가중치에 의존하여 보정됨이 타당하다. 즉, 새로운 노드가 유입되어 노드 사이의 우선순위가 명백한 경우에는 기존의 노드가 일정 수준의 비중을 갖는 지식에 대한 관성력이 존재한다는 것이다.

(그림 3)는 관성 결합의 개념적 구조이다.

임의의 학습내용을 포함하고 있는 노드(N_{old})와 학습과정에서 N_{old} 을 근거로 해서 생성된 새로운 노드(N_{imp})에 대한 각각의 노드값 α, β 는 서로 상이할 수 있다($\alpha \neq \beta$).

이러한 경우, N_{imp} 의 노드값 β 에 대한 전(全)적인 수용은 학습된 기존 지식 N_{old} 의 붕괴를 의미한다. 이에 사고의 관성을 인정하여 N_{old} 의 노드값 α 의 관성작용에 N_{imp} 의 노드값 β 가 보정되어야 하고, 이 때 산출규칙에 의해 계산된 값 $val_{\beta\alpha}$ 을 근거로 하여 동일구조의 새로운 노드 $N_{\beta\alpha}$ 로 보정



(그림 3) 관성 결합에서의 개념적 구조

〈표 1〉 지식관성률의 산출

```

float valnode, learningtime, valaccumulated; // 변수 정의
float kappa; // 지식관성상수 정의
float k[maxnode], Ktotal; // 개별노드와 객체의 지식관성률 정의

define ki = fsig {  $\frac{\kappa}{n} [val_i(n-1) - \frac{sup(\forall val_{node})}{2}]^2 \sum_j^n \Delta w_{ij}$  } f(ki)

define K = fsig {  $\frac{\kappa}{mn} \sum_i^m [val_i(n-1) - \frac{sup(\forall val_{node})}{2}]^2 \sum_j^n \Delta w_{ij}$  } f(K)

while (∀ node) {
  GetValueFromNode(nodei); // i 번째 개별노드의 멤버값 획득
  k[i]=f(ki); // i 번째 개별노드의 지식관성률 산출
}
K=f(K); // fsig-1(k[i]) 후 객체의 지식관성률 산출

```

된다. 또한 1차 산출된 $val_{\beta\alpha}$ 에 의해 해당노드를 구성하는 하위노드값과 연결가중치들이 하향 보정된다.

한 개인의 지식은 적당한 맥락 속에서 생성하여 유지되고, 특수한 상황에서 사고하거나 행동하는 양식은 그 사람의 인지 구조에 의하여 결정된다[16]. 이는 기존의 지식에 새로운 지식이 결합하여 기존의 지식을 변형함으로써, 또 다른 새로운 지식을 만들어 내는 것과 같으며, 이 과정에서 기존 지식의 성향이나 특성이 어느 정도 유지됨을 의미한다. 즉, 인간의 지각 활동에는 이미 습득되어 정착된 선입견과 같은 지식이 존재하여 외부에서 이 지식과 배반되는 지식이 유입되는 경우, 기존의 지식을 유지하려 하는데, 이는 기존지식과 유입지식 간의 배반 정도가 클수록 더 강하게 표현되는 경향이 있다[6].

이에 본 연구에서는 이러한 사고의 관성을 비중, 즉 확률적 의미로 해석하고 물리적인 관성모멘트를 기반으로 지식관성률(inertia of knowledge)을 정의한다.

물리적 관성모멘트(moment of inertia)는 관성의 크기를 나타내는 물리량으로, 임의의 물체가 그 때의 상태를 유지하려는 크기를 말하며, 축에서의 거리가 $r_{i|i=1,2,\dots,n}$ 인 질점(質點) $m_{i|i=1,2,\dots,n}$ 으로 이루어진 물체의 관성모멘트 I 는 $I = \sum_i^n r_i^2 m_i$ 로 정의한다.

이 때, 학습자 인지구조 객체를 물리적인 임의의 물체를 상정하면, 축에서의 거리 r 은 두 노드값 간의 거리 $|\alpha - \beta|$ 로, 그리고 질점 m 은 해당 노드값 α_{old} 이 가지는 중심으로 부터의 이격거리($|\alpha_{old} - \frac{sup(\forall val_{node})}{2}|$)와 대응될 수 있다. 여기에서의 이격거리는 무의미값과의 차이로서 학습(self-learning)

과정에서 확보된 해당 노드의 가치를 의미한다.

이러한 가정은 기존 지식의 인지정도 그리고 기존 지식과의 배반정도가 클수록 기존의 지식을 유지하려는 경향이 높을 것이라는 상식적인 수준의 사고의 관성과도 논리적으로 충돌하지 않는다.

관성모멘트가 물체 내에 존재하는 모든 r_i , m_i 를 독립변수로 취급함과 같이 인지에서의 지식관성도 개별 학습자 인지구조 내의 모든 노드 및 방향성 결합을 포함하는 총체적인 관성을 고려해야 한다. 즉, 지식관성은 인지구조 객체의 총체적 관성(K)과 객체를 구성하는 개별 요소들의 지식관성($k_{i|i=1,2,\dots,n}$) 간의 관계가 전제되어야 하며, 이에 따라 학습자 인지구조 객체의 관성은 개별 노드의 관성의 합($K = f(\sum_i^n k_i)$)으로 표현하는 것이 타당하다.

이에 물체의 물리적 관성모멘트를 수용하고 인지구조 객체를 구성하는 개별 노드에 대한 지식관성의 개념을 포함하는 지식관성률은 다음과 같은 산술적인 전개가 가능하다.

임의 수준 학습된 개별 학습자의 인지구조 객체는 학습과정에서 특정 노드(i -노드)의 기존 노드값(val_{old})과 실제 입력값(val_{imp})사이에는 오차를 의미하는 차이(Δw_i)가 존재하고, 이 Δw_i 는 해당 노드가 학습의 과정에 관여할 때마다 상이한 값이 발생하며, 학습의 횟수에 의존하여 크기는 감소한다. 이에 지속적으로 일정 크기 이상의 차이를 발생시키는 노드는 지식관성률이 낮게 산출되어야 함을 의미한다.

또한, i -노드의 n 번째 학습에 관여하는 $(n-1)$ 번째 노드값과 관성중심과의 편차, 즉 i -노드의 거리인 $|val_i(n-1) - \frac{sup(\forall val_{node})}{2}|$ 도 관성의 개념에 따라 i -노드의 지식관성률 k_i 에 비례한다.

따라서

$$k_i = f_{sig} \left\{ \frac{\kappa}{n} [val_i(n-1) - \frac{sup(\forall val_{node})}{2}]^2 \sum_j \Delta w_{ij} \right\} \quad (3)$$

(단, $f_{sig}(t) = \frac{1}{1+e^{-t}} + \frac{1}{2}$, $\Delta w_i = |val_{old} - val_{imp}|$, κ is a

constant)

이며,

학습자 인지구조 객체의 총체적 지식관성률 K 는

$$K = f_{sig} \left\{ \frac{\kappa}{mn} \sum_i [val_i(n-1) - \frac{sup(\forall val_{node})}{2}]^2 \sum_j \Delta w_{ij} \right\} \quad (4)$$

이다.

이상의 전개에 의해 산출된 k_i 는 해당 단위지식에 대한 학습자의 사고성향 및 인지방식을, K 는 해당 도메인 전체에 대한 지식구조, 더 나아가 학습자 개인의 지식 기호(嗜好) 또는 선입견 등 학습자가 자신의 기존 지식을 유지하려는 개인적인 성향을 정량화한 척도로 사용 가능하다.

한편, 지식 관성률 k_i 의 산출의 근간이 되는 각 노드값과 연결가중치의 보정은 X-Neuronet의 산출 규칙에 의존한다. 학습자 인지구조 객체의 초기 학습은 무관성 보정(inertia-less revision)한다. 즉, 학습 과정시 추출되는 학습자 반응에 의한 추정값과 기존 노드값의 평균값에 의해 새로운 노드값을 산출한다. 이 때 보정 횟수와 보정된 총 간격을 저장하여 임의 횟수 이상 학습이 진행되었을 경우에 저장된 두 값을 근거로 하여 각 노드별로 지식 관성률 k_i 을 산출하며, 학습의 횟수가 거듭될수록 k_i 는 임의의 값에 수렴한다.

따라서 임의 수준 이상 학습된 지식결합체에서의 지식 관성률 k_i 는 해당 학습자의 지식이 해당 노드의 내용에 대한 안정적인 학습이 되었는가에 대한 판단 근거를 제공할 수 있다.

3.2.2 지식관성률의 추출

학습자의 인지구조 객체를 구성하는 노드는 단순노드(simple node)와 복합노드(complex node; linked node)로 구분한다. 여기에서의 단순노드는 각각의 문항과 학습요소를, 그리고 복합노드는 학습요소와 문항이 연결된 방향성 결합체를 의미하며 구조체의 형식으로 구체화한다. 단순노드는 노드의 일련번호, 노드의 실제적 내용인 기본요소, 해당 노드의 학습(self-learning) 횟수 그리고 학습시 산출된 해당 노드의 누적변화량($\sum_{i=1}^n |val_{i-1} - val_i|$)을 멤버(member)로 갖으며, 복합노드는 일련번호, 출발과 목적노드의 일련번호, 두 노드 사이의 연결가중치, 해당 노드의 학습 횟수 그리고 학습시 산출된 해당 노드의 누적변화량을 멤버로 갖는다. 단순노드와 복합노드를 기술하는 구조체(structure)는 영역전문가에 의해 제시된 문항과 문항의 분할 결과에 기반한다.

영역전문가에 의해 제시된 모든 문항을 분할하고 이들 사이의 관계를 표현하면 하나의 방향성 결합체로서의 위상적

구조를 가지는데, 이 때 형성된 위상 구조의 표상과 소유자의 ID를 캡슐화하여 학습자 인지구조 클래스를 구현한다.

학습자 인지구조 클래스는 소유자 ID와 각 노드의 구조체 멤버들을 초기화하여 개별 학습자에게 할당되고, 할당된 클래스는 개별 학습자의 문항 반응을 입력값으로 처리하며 해당 학습자의 인지구조를 모방하는 개별 학습자의 인지구조 객체로 역할을 수행한다.

임의 수준 학습된 인지구조 객체에서의 지식관성률 산출은 해당 객체에서 추출된 멤버값(Node.node_value, Node.learning_number, Node.accumulated_value)과 식 (3)과 (4)의 규칙에 의하여 추출 알고리즘은 <표 1>과 같다.

3.3. 적용 가능성 모색

학습자 특성, 특히 학습자의 인지구조와 인지양식을 효과적으로 정량화하기 위해 적용하고자 하는 도메인을 대상으로 문항을 제작하고, 이들 문항을 교수·학습 과정상의 학습요소 단위로 다층 분할한다. 이 때 제작된 문항을 문항층에, 분할된 학습요소는 다층의 학습요소층에 위치시키며 의미적인 포함관계를 기준으로 방향성 결합을 결정한다.

모든 문항에 대해 이와 같은 반복적인 수행 그리고 직접적으로 관련성이 없는 모든 노드의 결합도 방향성 결합을 취하여 학습자 인지의 위상적 구조를 구축한다.

본 연구의 관심은 대상 도메인을 분할하여 캡슐화한 구조체 형식의 개별 학습자 인지구조에서 어떠한 단위노드 또는 결합노드를 특정 학습 과정에서 어느 정도의 비중으로 인정할 수 있는나는 것, 즉 어느 순간에 노드가 가지는 노드값을 충분히 신뢰할 수 있는나는 것에서 출발한다.

이러한 관점에서 본 연구에 의해 정량화된 학습자 인지구조 객체의 총체적인 지식관성률과 노드의 개별 지식관성률은 객체 및 노드의 안정화 정도를 판단할 근거를 제공한다. 일반적인 신경망적 개념에서 안정화가 가능한 충분한 횟수의 학습이 이루어진 객체는 높은 지식관성률을 가질 수 있지만 이는 그 객체에 일관된 입력값이 지속적으로 개입하는 경우를 전제한다. 따라서 교수·학습 과정에서 학습자의 반응을 입력값으로 채택하는 경우는 입력값에 대한 일관성을 보장할 수 없어 어느 순간에 나타난 특정 노드값을 전적으로 신뢰할 수는 없다. 이에 이러한 문제점을 보완하기 위한 구조적 보정기능으로서 지식관성률의 적용은 충분한 개연성을 갖는다.

임의 학습자의 인지구조 객체 또는 해당 객체 내 특정 노드가 안정화되었는가는 대상 노드의 노드값을 어느 정도 신뢰할 수 있는가와 의미를 같이하는데, 이를 정량화한 수치는 획득된 개별 노드의 노드값과 지식관성력 그리고 객체 전체에 대한 지식관성력에 의존한다. 따라서 노드의 신뢰도(c)는 해당 노드의 노드값과 지식관성력 그리고 객체 전체의 지식관성력을 독립변수로 갖는 $c = f(\text{Node}(w_i, k_i, K))$ 의 관계에 의해 산출될 수 있고 이는 실험적으로 다음 식 (5)와 같이 정형화가 가능하다.


$$c = \frac{\tau}{1 + e^{-w_i \cdot k_i \cdot K}}, \tau \text{ is a constant} \quad (5)$$

학습자 인지구조 객체의 안정화가 인정되는 경우, 교수·학습 과정으로의 효과적인 적용을 위해서는 노드의 사용 목적에 적합한 학습 요소의 추출이 가능해야 한다.

본 연구에서는 학습 요소의 적절한 추출을 위해 추출의 방법을 최저(minimum) 추출, 최고(maximum) 추출 그리고 최적(optimal) 추출로 분류한다.

최저 추출은 학습자 인지구조 객체 내의 모든 노드 중 지식 관성력이 가장 작은 노드를 추출하는 것으로, 최저 추출에 의해 선택된 노드는 해당 지식 자체가 소유자의 지식 구조 내에 안정화되지 않은 상태로 존재한다는 것을 의미한다. 즉 이러한 노드는 교수·학습 과정에서 순차적으로 우선 투입되어 임의 수준 이상의 학습이 이루어져야 한다는 것이다.

최고 추출은 학습자 인지구조 객체 내의 모든 노드 중 지식 관성력이 가장 큰 노드를 추출하는 것으로, 최고 추출에 의해 선택된 노드는 해당 지식 자체가 소유자의 지식 구조 내에 이미 충분히 안정화되어 어느 정도의 배반된 지식의 유입에도 지식 변형이 발생하지 않는다는 것을 의미한다. 따라서 이러한 노드는 교수·학습 과정에서 학습을 위한 도구적 지식으로 사용이 가능하다는 것이다. 예를 들어 '사각형'에 대한 지도에서 '사각형'의 하위 요소인 '평행사변형', '직사각형', 그리고 '정사각형'의 관성력 중 '평행사변형'의 관

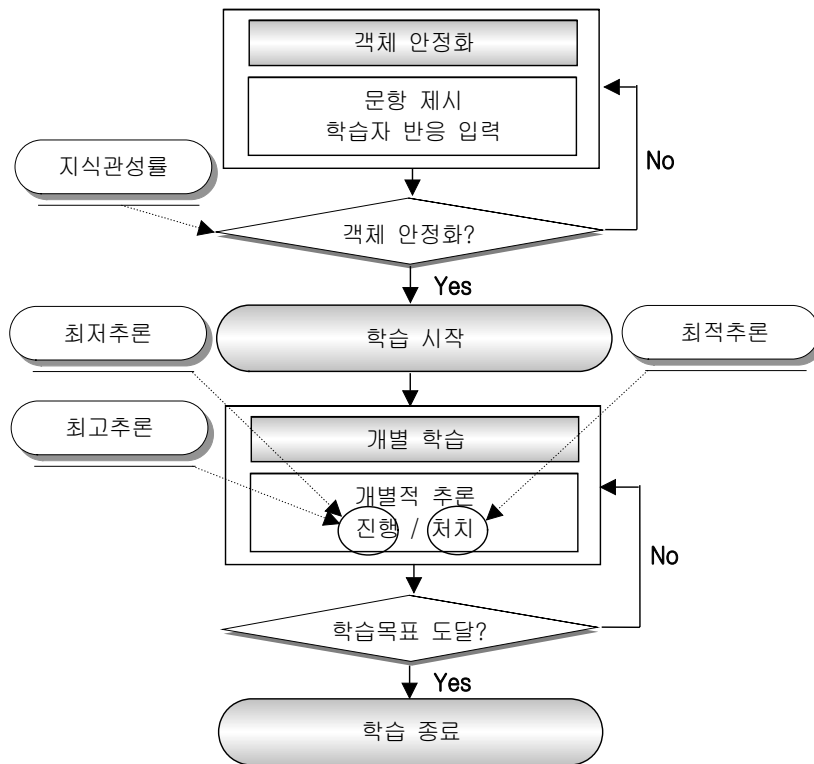


(그림 4) 최적 추출의 사례

성력이 가장 높은 경우 '평행사변형'의 개념을 이용하여 '사각형'을 설명하는 것이 효율적인 측면에서 바람직하다는 것이다. 하지만 이러한 최고 추출에 의해 선택된 노드가 항상 옳은 지식을 표현하지는 못하고, 이에 오류가 없는 지식을 관심의 대상으로 상정할 필요가 있다.

최적 추출은 특정 학습자의 교수·학습 과정에서 형성된 지식 단위 중 가장 신뢰할 수 있다고 인정되는 노드의 추출에 관심을 갖는다. 이 최적 추출의 과정에는 특정 학습자의 임의 수준 학습된 인지구조 객체에 기반하여 획득한 개별 노드들의 정확도와 지식관성력 그리고 객체 전체의 총체적인 지식 관성력이 개입한다. 따라서 노드의 정확도, 개별 노드의 지식관성력 그리고 객체 전체의 지식관성력을 독립변수로 하는 함수값에 의해 임계치(θ)이 산출되어 임계함수는 식 (5)의 신뢰도 함수를 적용할 수 있다.

이에 따라 (그림 4)와 같이 형성된 학습자의 인지구조 객체에서 ' $E_2 \rightarrow P_1$ '의 지식이 ' $E_1 \rightarrow P_1$ '에 비해 전체적으로 높은 정확도를 보이거나, 낮은 관성률로 인하여 지식 자체에 대



(그림 5) 학습자 특성의 개입

한 신뢰도는 상대적으로 낮아져 (그림 4)를 소유하고 있는 학습자에게 'E₁ → P₁'와 관련된 지식이 우선해야 한다는 것이다.

교수·학습 과정에서 개별 학습자 인지구조 객체에 기반한 학습 요소의 추출 방식은 (그림 5)와 같이 발생하는 상황에 의해 선택적으로 적용된다.

첫째, 학습의 진행을 위한 학습요소의 추출 상황을 전제한다면, 학습의 출발점인 경우, 즉 학습의 위한 실마리는 제공하는 의미로서의 추출은 최저 추출과 최고 추출이 모두 유의미하나, 학습 내용의 설명을 위해서는 최적 추출의 방식에 의해 도출된 학습 요소의 투입이 적절하다.

둘째, 학습자 오류의 원인 분석, 즉 학습자가 획득한 오개념에 대한 수정(feedback)을 위한 과정으로서의 추출이라면, 최저 추출이 유용하며, 해당 노드의 설명을 위해서는 최적 추출에 의해 도출된 학습 요소가 적합하다.

4. 실험 및 검증

본 연구에 의해 표상된 학습자 특성의 적용 타당성을 확보하기 위해 개별 학습자 인지구조 객체에서 추출한 학습 요소가 해당 학습자에게 충분히 적합한가에 대한 검증을 실시하였다.

이에 본 검증에서는 고등학교 1학년 수학 교과와 '삼각함수' 단원을 도메인으로 30명의 학습자를 실험대상으로 선정하였다. 영역 전문가에 의해 제작된 평가문항을 사용하여 실험집단에 대한 지필평가를 실시하였고, 평가 결과 획득된 학습자의 반응을 처리하였다. 이 때 제작된 평가문제에 기반한 학습자 인지구조 객체의 구성과 학습(self-learning)을 위하여 실험 모듈을 구현하였다. 또한 개별 학습자의 객체에서 추출된 하위 학습요소가 실제적으로 학습자에게 적합한지를 판단하기 위해 하위학습요소 목록을 나열하여 선택하도록 하였다.

검증을 위한 실험 절차는 다음과 같다.

(단계 1) 영역전문가에게 의해 고등학교 1학년 수학을 대상 도메인으로 하여 20개의 평가문항을 제작한다.

(단계 2) 제작된 평가문항을 분석하여 문항총과 다층의 학습요소층을 결정한다. 즉, 제작된 각 문항은 문항 자체가 포함하는 세부 학습요소 및 개념 단위로 분할하여 하위노드 설정을 위한 근거로 사용한다.

(단계 3) 추출된 대상 문항과 하위노드들을 유형 결합하여 전체 인지구조 표현을 위한 방향성 그래프의 부분(subset)으로 구성하며 이러한 과정의 반복 수행과 직접적으로 관련성이 없는 모든 노드의 방향성 결합을 합하여 학습자 인지구조의 기본적인 틀(frame)을 구축한다.

(단계 4) 제작된 문제지를 통해 학습자 평가를 실시한다.

(단계 5) 학습자의 평가 결과를 기반으로 실험대상 30명 각각에 대한 개별 학습자 인지구조 객체를 학습시키고 30개의 학습자 인지구조 객체(object #01, object #02, ..., object #30)를 획득한다.

〈표 2〉 추출순위와 선호순위의 추출 사례

학습요소	st #01		st #02		st #30	
	추출 순위	선호 순위	추출 순위	선호 순위	추출 순위	선호 순위
빗변	1	2	1	2	1	1
달음비	8	7	3	6	3	7
원	13	8	5	3	7	8
직각 삼각형	6	13	10	8	11	13
여각	10	12	4	5	5	12
자취, 길이	5	9	6	4	5	6
좌표	10	6	13	12	13	9
특수각	9	10	8	1	8	10
SIN	2	2	2	7	3	2
COS	6	1	12	13	11	4
TAN	12	11	10	11	9	11
관계1	3	3	6	9	2	3
관계2	4	4	8	10	10	4
r_s	0.618		0.689		0.500	
t	2.608		3.157		1.915*	

(단계 6) 학습된 개별 학습자의 인지구조 객체에서 최적 추출의 결과를 개개의 학습자별로 서열화하여 학습요소 목록을 작성한다.

(단계 7) 학습자 인지구조를 기반으로 하위 학습요소를 추출하여 학습자들에게 학습요소의 서열화된 설문지를 제시하고 이에 대한 개별 반응을 수합한다.

(단계 8) 획득한 결과를 분석한다. 특히 학습자 인지구조 객체의 학습자 적응성 검증을 위해서 객체에서 추출된 학습 요소와 학습자에 의한 서열적으로 선택된 학습요소 사이의 상관성을 파악하며 추출 사례는 <표 2>와 같다. 이 때 Spearman의 등위상관계수(r_s)의 의의도(t)를 사용한다.

<표 3>은 학습자 반응의 입력과 학습(self-learning) 후에 형성된 개별 학습자 인지구조 객체(object #n)에서 최적 추출에 의해 선정된 학습요소 순위와 학습자(student #n)에 의해 선택된 선호 순위 사이의 관계에서 Spearman 등위상관계수(r_s)와 의의도(t)를 정리한 것이다. 여기에서 대부분(87%)의 최적추출의 결과가 유의미하게($\alpha=.05$) 소유자의 선호도와 유사하여 최적추출의 결과는 개별 학습자의 인지적 특성을 포함한다고 할 수 있다. 따라서 객체의 학습자 적응성에 대한 결론을 내리기에 충분하다.

〈표 3〉 최적추출 결과와 선호도 사이의 Spearman
등위상관계수

번호	r_s	t	번호	r_s	t	번호	r_s	t
1	.618	2.608	11	.794	4.331	21	.827	4.877
2	.689	3.157	12	.585	2.393	22	.689	3.158
3	.736	2.480	13	.690	2.763	23	.797	4.372
4	.645	2.803	14	.464	1.738*	24	.495	1.887*
5	.764	3.924	15	.634	2.723	25	.604	2.516
6	.695	3.206	16	.582	2.376	26	.582	2.376
7	.824	4.826	17	.733	3.579	27	.604	2.516
8	.708	3.332	18	.656	2.887	28	.887	6.383
9	.582	2.376	19	.535	2.104	29	.640	2.763
10	.561	2.244	20	.475	1.791*	30	.500	1.915*

5. 결론 및 제언

본 연구에서는 학습자 특성, 특히 학습자의 인지구조와 인지양식을 연결주의적 관점에서 표상하고 이를 기반으로 정량화 기법을 제안하였으며 또한 실험을 통하여 그 타당성을 검증하고 적용 가능성을 모색하였다.

본 연구에서의 인지구조는 기존 연구의 학습자 인지구조 객체를 간소화하여 표상하였고, 인지양식은 학습자의 지식 관성력으로 제한하여 추출하였다. 또한 학습자 특성을 효과적으로 정량화하기 위해 인지(cognition)의 위상적 구조인 학습자 인지구조 클래스를 특정 교과 및 단원을 대상으로 실제화하였다. 이 실제화는 영역 전문가에 의한 문항 제작, 제작된 문항의 분할 및 층(layer)의 결정 그리고 분할된 학습요소의 유형 결합에 의한 인지구조의 표현에 의해 순차적으로 진행하였다. 제작된 문항을 평가도구로 하여 실시한 학습자 지필평가 결과를 학습자 반응에 대한 입력값으로 개별 학습자의 인지구조 객체를 학습(self-learning)시키고 이 학습 과정에 본 연구에서 개발된 인지구조 객체의 학습모듈을 사용하였다. 임의 수준 학습된 개별 학습자 인지구조 객체는 해당 학습자의 지식상태와 상관관계가 충분히 높아 객체를 통한 학습자의 인지구조 및 인지상태에 대한 파악 기회를 제공하였다. 또한 표상된 학습자의 인지구조 객체를 이용한 산출함수와 알고리즘에 의해 학습자의 지식관성률을 산출하였으며 이를 적용할 수 있는 가능성을 모색하였다.

하지만, 본 연구에 의해 표상과 적용의 가능성이 긍정적이더라도 차후 이 구조 및 상태의 정량화에 대한 심층적인 보안을 위해 표집의 확대 및 함수의 정교화가 이루어져야 한다. 또한, 본 기법에 대한 적용 가능성을 충분히 보장받기 위해 다양한 유형의 적용 모형에 대한 연구가 추가적으로 필요하다.

참 고 문 헌

[1] 강이철, 교육공학의 이론과 실제, 서울: 학지사, 2001.
 [2] 김용범, 김영식, “지능형 교육 시스템을 위한 적응적 지식베이스 객체 모형 개발,” 정보처리학회논문지B, 제13-B권 제4호, pp.117-134, 2006.
 [3] 김형수, 김동일, 황애경, “학습자 특성 및 적용 영역별 인지학습 전략의 효과,” 교육과학연구, 제37집 제2호, pp.43-74, 2006.
 [4] 김호중, 실용트리즈의 창의성 과학, 두양사, 2006.
 [5] 전성연, “개별화와 협동화: 실천적 전개를 위한 통합의 논리,” 교육방법연구 제17권 2호, pp.161-182, 2005.
 [6] 오세진 외, 인간행동과 심리학, 학지사, pp.159~196, 1999.
 [7] 이옥화, “신세대 학습자 특성 분석: 대학생의 사이버 커뮤니티 이용 특성,” 컴퓨터교육학회논문지 제8권 4호, pp.1-12, 2006.
 [8] 이홍우, 교육의 목적과 난점, 서울: 교육과학사, pp.447-448, 1994.
 [9] 장혜정, 장은정, “웹기반 소집단 협력학습에서 학습자 성격 특성과 상호작용자 유형에 따른 학습결과 분석,” 교육과학연구 제 24권 1호, pp.137-167, 2008.
 [10] 호재숙 외, 교육방법 및 교육공학, 교육과학사, pp.230-233, 1994.
 [11] B.T.Low, H.C.Lui, A.H.Tan and H.H.Teh, “Connectionist Expert System with Adaptive Learning Capability”, IEEE Transactions on Knowledge and Data Engineering, Vol.3(2), pp.200-207, 1991.
 [12] Chia H W-K, C-L Tan, “Association- based evolution of comprehensive neural logic networks”, GECCO 2004, pp.26-30 June 2004, Seattle, Washington, USA, 2004.
 [13] Dixon, N. M., Common knowledge: How companies thrive by sharing what they know. Boston, Massachusetts: Harvard Business School Press, 2000.
 [14] Jonassen, D.H. and Grabowski, B.L., Handbook of Individual deferences, learning, and instrection, Hillsdale, NJ: Lawence Erlbaum, 1993.
 [15] J. F. Soltis, An Introduction to the Analysis of Educational Concepts, Massachusetts: Addison-Wesley Publishing Company, pp.7-10, 1968.
 [16] Piaget, J., “Piaget’s Theory”, In P. Mussen(Ed.) Handbook of child psychology, Wiley, 1983.
 [17] Quinlan, P., Connectionism and psycholgy: A psychological perspective on new connectionist research, Chicago: Chicago U. Press, 1991.
 [18] Rumelhart, D.E., McClelland, J.L. and LNR Group, Parallel distributed processing: Explorations in the microstructure of cognition (Vol. 1), Cambridge, MA: MIT Press, 1986.
 [19] Tiedemann, J., “A study of field independent biased mental ability tests in community college science classes”, Journal Research in Science Teaching, 23, pp.817-822, 1989.
 [20] Wringe, D.S., “The Teacher’s task”, in Philosophy and the Teacher(Ed.), D. I. Lloyd, London: Routledge & Kegan Paul, 1976.



김 용 범

e-mail : kybhj@hanmail.net
1989년 한국교원대학교 수학교육과
(교육학사)
2001년 한국교원대학교 컴퓨터교육과
(교육학석사)
2007년 한국교원대학교 컴퓨터교육과
(교육학박사)

2007년~현재 충남 금산여자고등학교 교사
관심분야 : 컴퓨터교육, ITS, 원격교육



김 영 식

e-mail : kimys@mail.knue.ac.kr
1982년 서울대학교 전기공학과(공학사)
1987년 노스캐롤라이나주립대학교 전기
및 컴퓨터공학과(공학석사)
1993년 노스캐롤라이나주립대학교 전기
및 컴퓨터공학과(공학박사)

1993년~1994년 한국전자통신연구소 선임연구원
1995년~1996년 한국전자통신연구소 위촉연구원
1996년~1998년 한국전자통신연구원 초빙연구원
1994년~현재 한국교원대학교 컴퓨터교육과 교수
관심분야 : ITS, e-learning, 디지털 영상처리, 컴퓨터 구조