

수평적 학습객체로 구성된 e-러닝 콘텐츠의 개인 맞춤형 학습시스템 구축 방안

A Construction Scheme for the Personalized e-Learning System Composed of Horizontal Learning Objects

오용선
목원대학교

Oh, Yong-Sun
Mokwon University

요약

본 논문에서는 대단원 밑에 형성되는 학습단위 혹은 학습마디에 계층성이 없는 수평적 학습객체가 다수 존재하는 e-러닝 콘텐츠에 대하여, 문항반응이론에 입각한 개인 맞춤형 학습시스템을 구축하는 새로운 방안을 제안한다. 특히 제안된 학습시스템은 평가단계와 학습단계를 명백히 구분하여 제공하는 기존의 방식에서 벗어나, 학습마디의 운영중에 평가를 진행하고 그 결과에 따라 피험자의 능력을 재추정하여 이를 다음 학습마디의 운영에 적용하는 평가-학습의ダイナミック한 연계를 추구한다. 또한 적절한 대단원이 종료되는 시점에서 학습마디의 난이도 평균과 문항특성을 수정하고, 학습자 혹은 피험자들의 능력 추정치도 변경함으로써 더욱 정확한 개인 맞춤형 학습이 이루어지도록 조치한다. 이러한 구축 방안은 e-러닝 콘텐츠 학습과정을 통하여 변화하는 학습자 능력을 추정하여 가장 적절한 학습내용과 문항을 제공함으로써 학습효과를 극대화하며, 주기적으로 학습시스템 자체의 모수들을 수정함으로써 지속적인 개선 효과를 얻을 수 있다.

Abstract

In this paper, we propose a novel construction scheme for the personalized e-Learning system based on IRT(item response theory), which can be applied to the content including non-hierarchical and horizontal learning objects in its learning nodes. Especially the proposed system performs tests and re-estimates examinee ability during the learning nodes are operating so that the results are directly applied to the next node. This scheme can be called a dynamic relationship between test and learning which is totally different from conventional customization based on learning procedures separated from test steps. Moreover, we should periodically modify the averages of node difficulties, item parameters, and ability parameters of students so that the system have more accurate personalized learning capability. As a result, this scheme maximizes learning efficiency offering the most appropriate learning objects and items to the individual students according to their estimated abilities and the system itself should obtain continuous improvements by modifying the parameters and fulfilling periodical feedbacks.

I. 서론

개인 맞춤형 교육(personalized education)은 이러닝 뿐 아니라 일반 오프라인 교육에 있어서도 매우 중시되는 문제로 모든 교육의 궁극적 목표 중 하나이다. 특히 온라인 웹 기반 교육을 특징으로 하는 이러닝에 있어서, 학습자의 특성을 정확히 평가하여 그에 적절한 학습객체를 제공함으로써 교육의 효과를 극대화하는 맞춤형 교육의 개념은 일찍부터 도입되었다 [1].

그러나 맞춤형을 지향하는 대부분의 체계가 학습자의 선호도, 흥미도 혹은 웹 검색습관 등을 고려하여 개인별로 학습객체를 제공하는 방식이거나[2], 학습자 스스로 특정한 학습객체

를 선택하여 반복 학습할 수 있도록 개념단위를 도입한 방식 등에 국한되고[3], 실제로 학습자의 능력(ability)을 고려한 최적 난이도(difficulty)의 학습객체나 문항을 제공하는 시스템의 구현을 보인 경우는 매우 드물다.

2000년대 중·후반 들어서면서, 맞춤형 이러닝을 위해서는 학습자의 능력과 학습객체의 난이도가 동시에 고려되어야 하며, 이를 위하여 평가(test)와 학습(learning)이 긴밀하게 연계되어야 한다는 논리가 설득력을 얻기 시작하였으며, 소위 문항반응이론(IRT: Item Response Theory)[4]에 의한 평가와 그 결과에 따른 학습내용 구성을 요지로 하는 연구들이 이루어졌다.

지금까지 문항반응이론을 기반으로 이루어진 이러닝에 관한 연구들을 살펴보면, 학습자의 능력에 따라 적절한 문항을 제공하기 위한 문제은행의 구축이나, 평가와 학습을 연계시키기 위한 적용 등이 주를 이루고 있으며[5][6], 특히 평가와 학습을 동적으로 연계하여 학습효과를 극대화할 수 있는 이러닝 시스템에 관한 연구가 최근의 이슈가 되고 있다[7][8]. 그러나 이들 연구에 있어서는 평가과정과 학습과정을 충분히 동적으로 연계시키지 못하고 두 과정이 실질적으로 분리되어 있거나, 두 과정이 혹 충분한 연계성을 갖고 있다 하더라도 제공되는 문항이 학습내용을 평가하지 못하고 단지 문항모수(item parameters)나 학습자 능력모수(ability parameter)를 추정하는데 국한되어 추정의 신빙성을 확보하지 못하거나, 편향된 모델의 적용으로 변별도나 추측도를 고려하지 않음으로써 실질적인 시스템 개선을 위한 피드백도 충분히 제공할 수 없다는 단점이 있다.

이에, 본 논문에서는 학습객체와 공존하는 문항을 통하여 학습자 능력모수와 문항모수를 매년 재추정하여 최적의 동적 학습객체를 선별적으로 제공함으로써 개인 맞춤형 이러닝 시스템을 구축하는 새로운 방안을 제안한다. 전체 콘텐츠는 대단원과 소단원으로 계층화되고, 가장 작은 단위로는 [3]이 제안하고 있는 개념단위로 분리하여 SCO(sharable content object)를 형성한다. 또한, 유사한 학습내용을 포함하는 여러 개의 학습객체SCO와 그에 대한 문항으로 구성된 문항SCO들이 모여 하나의 재추정(re-estimation) 단위가 되는 마디(node)를 형성하는 방식으로 제작된다. 문항모수와 학습자 능력모수를 추정하기 위한 IRT의 모델로는 3-모수 로지스틱을 도입하고, 각 마디가 끝나는 시점에서 학습자 능력모수와 문항모수가 재추정되고, 추정된 학습자의 능력에 가장 적절한 학습마디를 선정하는 맞춤형 학습을 제공하는 것이다. 또한, 학기 혹은 학년 등 하나의 기간이 끝나면, 최종 자료를 추출하여 오프라인 추정을 실시함으로써 모수들을 비롯한 시스템을 재정비하고, 학습관리에 필요한 다양한 피드백 자료를 제공할 수 있다.

II. 문항반응이론과 로지스틱 모델


문항반응이론(이하 IRT)은 개별 문항의 특성에 의하여 검사의 모든 특성과 결과가 분석된다는 모토의 이론으로 고전검사이론과 상반된 개념이다. 특히 검사의 행정적 기능보다는 교수적 기능 및 상담적 기능을 중시하는 체계로서 검사의 결과는 주로 학습자를 위한 피드백, 학습기회 부여, 진단 및 치료 등에 활용됨을 기본으로 한다[9]. 본 논문에서 적용하고 있는 IRT의 핵심 내용은 다음과 같다.

1. 문항특성곡선과 문항모수

본 논문에서 활용하는 문항특성곡선(이하 ICC: Item Characteristic Curve)과 문항모수(item parameters)는 BILOG에서 제공하는 3-모수 로지스틱(3-parameter Logistic) 모델에 따른다[10][11].

그림1은 몇 가지 문항특성곡선의 형태와 그들의 문항모수를 개념적으로 나타낸 것이다. ICC에 있어서, (1)난이도(difficulty)는 '답을 맞힐 확률' $P(\theta) = 0.5$ 인 점에서의 피험자 능력값 θ 를 말하며 "b"로 표시한다. (2)변별도(discrimination)는 $P(\theta) = 0.5$ 인 점에서의 ICC의 기울기로 "a"로 표시하며, 마지막으로 추측도(guessing parameter)는 능력이 전혀 없는 피험자가 문항의 답을 맞힐 확률을 말하며, ICC의 좌단이 표시하는 확률값으로 정한다.

주지하는 바와 같이, 문항④는 문항③에 비하여 난이도가 높으며, 문항②는 문항①에 비하여 난이도는 같으나 변별도가 높다. 또한 문항③은 그림에 나타난 네 개의 문항 중 추측도가 가장 크다. 일반적으로 선다형 문항은 답지의 수에 반비례하는 추측도를 갖는다.



▶▶ 그림 1. 문항특성곡선과 문항모수

2. 문항반응 모델

본 논문에서 활용하는 3-모수 로지스틱 모델은 '답을 맞힐 확률'과 '피험자 능력'의 관계를 다음과 같이 정의하고 있다 [4].

$$P(\theta) = c + (1 - c) \frac{e^{a(\theta - b)}}{1 + e^{a(\theta - b)}} \quad (1)$$

이 모델은 정규오자이브(Normal ogive) 모델을 지수함수에 의하여 근사화한 것으로, 두 모델 사이에 나타나는 ICC의 차이점은 매우 작다. 한편, 로지스틱 모델은 정규분포의 누적분포함수가 갖는 적분항을 포함하지 않으므로 상대적으로 계산량이 작아 실시간으로 모수를 추정해야 하는 이러닝 시스템에의 적용에 유리하다.

[6]에서 사용한 2-모수 로지스틱 모델은 난이도와 변별도를

고려하나, 선다형 문항에서 나타나는 추측도를 배제한다. 또한, [7]과 [8]에서 사용하고 있는 Rasch 모델은 1-모수 로지스틱 모델과 동일한 것으로 난이도만을 고려하고 있다[12]. 본 논문에서 추측도를 포함하는 3-모수 모델을 적용하고자 하는 이유는 학습객체SCO를 평가하는 문항SCO들이 '선다형(multiple choice)'인 경우를 상정한다. 만일 문항들을 '행동형(actional)'만으로 구성하고 그에 대한 기술적 평가체계를 갖추도록 조치하였다면 2-모수 모델을 사용하여도 무방할 것이다.

3. 모수 추정

본 논문에서는 문항모수와 학습자 능력모수에 대한 추정을 크게 두 가지로 구분한다. 그 하나는 오프라인 추정(off-line estimation)으로 최초 시스템에 적용하기 위한 모수 추정과 학기 혹은 학년이 마친 상태에서 실시하는 보정과정을 말하며, 또 하나는 온라인 추정(on-line estimation)으로 개인 맞춤형 학습시스템을 운용하면서 학습 도중에 얻어지는 학습자의 문항반응을 이용하여 기존의 모수들을 재추정하는 과정이다.

오프라인 추정에 있어서는 추정과정에서의 계산시간은 문제가 되지 않으므로 될 수 있는 한 정확한 추정치의 산출을 목표로 한다. 따라서 BILOG에서 제공하는 MMLE(marginal max. likelihood estimation) 등 정밀한 추정방법을 따른다. 또한 오프라인 추정의 부산물로 나타나는 피드백 자료들은 학습시스템의 보정뿐 아니라 교육의 현장에서 매우 유용한 자료가 될 수 있도록 제공되어야 한다.

각 문항SCO들에 대한 ICC와 전체 문항을 포괄하는 TCC(test characteristic curve)는 다음과 같이 주어지는 진점수(true score)와 함께 학습자들의 최종적 평가에 유용하다.

$$TS(\theta) = \sum_{i=1}^N P_i(\theta), \text{ where } P_i(\theta) : ICC \quad (2)$$

검사정보함수(test information function)와 능력추정의 표준오차(standard error of ability estimation)는

$$I(\theta) = \sum_{i=1}^N I_i(\theta), \text{ where } I_i(\theta) = a_i^2 P_i(\theta) Q_i(\theta) \quad (3)$$

$$SE_A(\theta) = \frac{1}{\sqrt{I(\theta)}} \quad (4)$$

와 같이 각각 주어진다. 여기서 $Q_i = 1 - P_i$ 를 나타낸다. 검사정보함수는 맞춤형 학습시스템 운영에 있어서 학습객체

SCO를 선택하는 기준으로 사용할 수도 있으나, 여기서는 검사의 정보량을 측정하는 것으로 운영이 지속될수록 그 값이 커질 것으로 예상된다. 능력추정의 표준오차는 정보량의 역에 비례하므로 운영이 지속되어 추정이 정확해지면 그 값이 점차로 작아질 것이다.

한편 온라인 추정에 있어서는 오프라인 추정에 비하여 짧은 계산시간과 간단한 알고리즘을 요한다. 이는 학습객체SCO와 문항SCO를 맞춤형으로 제공하는 기준을 마련하는 것으로 계산시간이나 복잡한 알고리즘에 의하여 실시간 지연이 발생하지 않아야 하기 때문이다. 변별도(a), 난이도(b), 추측도(c)의 추정은 다음과 같이 정의되는 Likelihood 함수를 최대로 하는 새로운 값으로 추정한다.

$$L(U|\theta) = \prod_{i=1}^N P_i(\theta)^{U_i} Q_i(\theta)^{1-U_i} \quad (5)$$

여기서 U_i 는 i 번째 문항에 대한 반응변수로서, 정답이면 1, 오답이면 0 값을 갖는다. 또한 이 식에서 모든 확률함수를 곱할 수 있는 것은 각 문항들의 독립성(local independence)에 의한다[11].

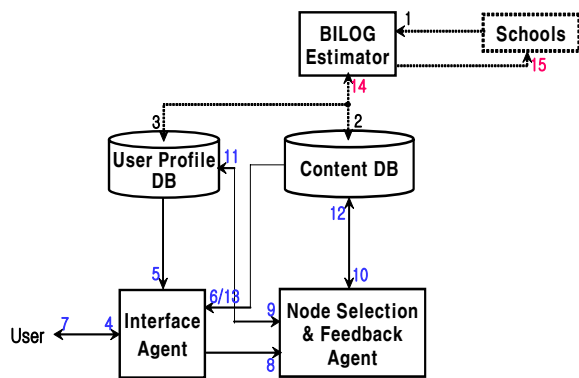
새로운 문항모수들이 추정되면, 기존의 학습자 능력모수와 문항반응을 이용하여 다음과 같이 새로운 능력모수를 추정한다.

$$\theta_n = \theta_{old} + \frac{\sum_{i=1}^N a_i [U_i - P_i(\theta_{old})]}{\sum_{i=1}^N a_i^2 P_i(\theta_{old}) Q_i(\theta_{old})} \quad (6)$$

여기서 θ_{old} 는 현재의 학습마디에서의 학습자 능력모수이며, θ_n 은 다음 학습마디에서 사용할 학습자 능력모수이다.

III. 시스템 구성과 운영 시나리오

이 장에서는 지금까지 전개한 문항반응이론의 추정 과정을 이용하여 맞춤형 학습을 제공하는 시스템의 구성과 그 운영 시나리오를 제시한다. 시스템의 구성은 [7]에서 제안한 시스템을 본 논문의 맞춤형 학습 과정에 적합하도록 수정하고, 최초 시스템 세팅과 학기말 시스템 보정을 위한 오프라인 추정과정을 포함하여 그림 2와 같이 설계하였다.



▶▶ 그림 2. 맞춤형 학습시스템 프레임워크

1. 콘텐츠 구성의 차별성

본 논문에서 추구하는 맞춤형 학습을 위해서는 전체 콘텐츠가 개념단위 오브젝트로 분할되어야 한다[3]. 우선 과목명과 대단원 혹은 차시에 따르는 계층적 분류는 기존의 콘텐츠 구성과 같다. 여기서 맞춤형 학습을 제공하기 위하여, 차시의 하위에 존재하는 학습객체의 단위로 학습마디(learning node)라는 개념을 도입한다. 학습마디는 문항모수와 학습자 능력모수가 재추정되는 단위로 그 내부에 여러 개의 학습객체SCO와 문항SCO가 존재한다. 이 때, 개념단위 오브젝트의 최소 단위는 SCO이다.

또한 본 논문에서는 이러한 학습마디가 그 상위 콘텐츠 오브젝트 내에 수평적으로 분포한다고 가정한다. 여기서 '수평적'이라는 말은 각 학습마디를 학습할 때 반드시 지켜야할 순서가 없다는 의미이다. 이는 다루고자 하는 교과목의 특성에 따른 것으로, 예컨대 수학이나 과학 같은 교과목은 수평적 특성을 갖지 못한다. 이와 같이 수평적 특성을 갖지 않는 경우에 대한 맞춤형 방안은 본 논문의 후속 연구로 다룰 예정이다.

학습마디 내의 모든 문항SCO는 추정된 문항모수를 소유하며, 그 학습마디가 종료되는 시점에서 매번 재추정된다. 학습객체SCO는 직접 관련된 문항SCO와 동일한 난이도 모수를 갖거나, 학습마디 내의 난이도 평균을 소유한다. 이와 같은 방법은 실제로 문항이 아닌 학습객체에 대해서도 난이도 모수를 소유하게 함으로써 동적인 맞춤형 학습과정을 제공하는데 중요한 역할을 하게 된다.

2. Agent와 DB의 구성

본 논문이 제안하는 맞춤형 학습을 구현하기 위하여 그림1과 같이, 두 개의 에이전트와 두 개의 데이터베이스를 구축하고, 이들의 상호작용을 정의한다.

인터페이스 에이전트(이하 'IF 에이전트')는 전형적인 HCI를 구현하는 것으로, 학습자 ID, Password를 비롯한 상태정보와 query 등을 전달한다. 특히 본 논문에서 중시하는 학습

객체의 전달 및 디스플레이, 그리고 학습자 문항반응의 중계 등이 추가적인 중요한 역할이다.

학습마디 선택 및 피드백 에이전트(이하 'NSF 에이전트')는 모수의 추정과 갱신 및 학습자 능력모수에 따른 학습마디의 선택과 제공을 담당한다. 온라인 맞춤형 학습 제공은 문항모수와 학습자 능력모수의 재추정 과정과 이에 따라 다양하게 일어나는 최적 학습마디의 선택 및 제공이 관건이다.

사용자 프로파일(User Profile) DB는 학습자의 상태정보, 회계정보, 문항반응벡터, 능력모수, 학습마디 수행정보 등을 유지·관리한다. IF 에이전트와의 상호작용으로 최근의 학습자 능력모수를 전달하고, NSF 에이전트로 하여금 최적의 학습마디를 선택하여 제공케 한다.

마지막으로 콘텐츠(Content) DB는 실질적으로 개념단위 오브젝트의 형태로 학습 콘텐츠를 유지·관리한다. 교과목으로부터 대단원, 차시, 학습마디 등의 계층을 유지하며, 학습마디 내의 학습객체SCO와 문항SCO를 관리한다. 전문가의 참여가 늘어날수록 SCO의 양은 증가할 것이므로, 이들에 대한 모수의 관리가 중요하다. 문항SCO에는 변별도, 난이도, 추측도 등의 모수들이, 학습객체SCO에는 난이도 모수가 유지·관리된다.

3. 운영 시나리오

그림 1의 시스템 구성으로, 본 논문이 추구하는 개인 맞춤형 학습을 실현하기 위하여, 전체적으로 시스템의 운영 시나리오를 오프라인 과정과 온라인 과정으로 구분하여 제시한다.

먼저, 오프라인 과정은 콘텐츠 제작을 비롯하여 시범운영, 초기 모수 추정, DB 초기화, 온라인 운영 후 피드백 데이터의 제공 및 시스템 보정을 위한 상세 모수 추정 등 시스템의 맞춤형 운영과는 별도로 학교와의 연계로 실현된다. 그림1에서 이를 점선으로 표시하고 있다.

<Step-0> 콘텐츠 제작 및 시범운영: 개념단위 오브젝트 형태의 콘텐츠를 제작하고, 이를 시범운영함으로써 초기 학습자 능력모수와 문항반응벡터를 추출한다. 문항반응벡터의 추출은 실제로 제작된 문항SCO에 대한 학습자들의 정·오답으로 하며, 초기 학습자 능력모수는 현재까지의 학습자 성적을 기준으로 -3부터 3까지의 모수로 추출한다.

<Step-1> 오프라인 문항모수 추정: BILOG 등 IRT를 사용하기 위한 패키지를 이용하여, 제작된 문항SCO들에 대한 문항모수 $a_i, b_i, c_i, i = 1, 2, \dots, N$ 들을 추출한다. 여기서 N 은 해당 학습마디 내에 존재하는 문항SCO의 수를 표시한다. 이 때, 추정을 위한 입력자료로는 학습자들의 초기 능력모

수 $\theta_j, j = 1, 2, \dots, M$ 와 이들의 문항반응 (1011100110110...) $j, j = 1, 2, \dots, M$ 이 된다. 여기서 M 은 참여한 피험자의 수를 나타낸다. 학습객체SCO는 어떤 문항SCO와 직접적으로 연관된 경우 그 문항SCO의 난이도를 따르며, 그렇지 않은 경우에는 해당 학습마디의 평균 난이도를 따른다. 학습객체SCO와 문항SCO의 연관성에 대한 판단은 문항 및 학습객체를 제작한 전문가에 의한다.

<Step-2> 제작된 콘텐츠 오브젝트와 초기 문항모수 저장: 문항SCO에는 초기 문항모수를, 학습객체SCO에는 연관된 문항SCO의 난이도나 해당 학습마디의 평균 난이도를 함께 저장하고, 적절한 학습마디를 형성하도록 SCO의 집단을 만들어 콘텐츠 DB에 저장한다.

<Step-3> 초기 학습자 프로파일 저장: 시범운영에 참여했던 피험자들을 중심으로 상태정보 및 능력모수 등을 사용자 프로파일 DB에 저장한다.

일단, 초기 학습자 프로파일 DB와 초기 콘텐츠 DB가 마련 되면, 온라인 개인 맞춤형 운영을 위한 준비가 완료된다. 온라인 운영을 통하여 새로운 학습자와 새로운 콘텐츠가 증가하고, 이에 따라 맞춤형 운영은 더욱 심도 있게 진행될 수 있다. 그림1에서 온라인 운영은 실선으로 표시되어 있다.

<Step-4> 학습자 로그인 및 코스 선택: 이미 프로파일이 설정된 학습자는 자신의 ID와 PW를 이용하여 로그인하며, 신규 사용자인 경우에는 등록 후 사용한다. 이 때, 신규 사용자는 프로파일 정보가 없으므로 그 능력모수를 '0'으로 시작하며 맞춤형 운영에 의하여 재추정된다. 로그인이 끝나면, 단원 혹은 차시를 선택하고, 순차적 모드 혹은 맞춤형 모드를 택일한다. 본 논문에서 추구하는 학습모드는 맞춤형 모드이나, 프로파일 정보가 없는 사용자가 자신의 능력모수를 우선 설정하기 위하여 순차적 모드도 선택할 수 있다.

<Step-5> 학습자 인증 및 능력모수 전달: 학습자 프로파일 정보에 따라 능력모수가 전달되고, IF 에이전트와 NSF 에이전트의 상호작용이 일어난다. 이 때, 프로파일 정보가 없는 초기 사용자의 능력모수는 '0'으로 전달된다.

<Step-6> 학습마디의 선택: 학습자의 능력모수에 따라 가장 적절한 학습마디를 선택한다. 여기서 가장 적절한 학습마디라 함은 학습자의 능력모수와 가장 가까운 난이도의 객체를 말한다. NSF에이전트는 최근의 학습자 능력모수 θ_n 와 접속 가능한 학습마디의 난이도를 비교하여 다음과 같이 주어지는

제공평균오류(mean-square error)를 최소로 하는 학습마디를 선택한다.

$$\overline{E_i^2} = \sum_{i=1}^N \frac{1}{N} (\theta_n - b_i)^2, i = 1, 2, \dots, N \quad (7)$$

여기서 N 은 해당 학습마디 내에 존재하는 문항SCO와 학습객체SCO의 수이다. 지금 θ_n 은 초기 능력모수를 표시하지만, 맞춤형 학습의 진행에 따라 지속적으로 재추정될 때 가장 최근의 추정치를 표시하게 된다.

학습마디를 선택하는 또 다른 방법으로 각 SCO의 정보함수(information function)를 합한 학습마디의 정보함수를 이용할 수 있다. 현재의 학습자에게 가장 큰 정보를 부여하는 학습마디를 선택하게 하는 것이다[6][7]. 그러나 이 방법은 본 논문의 LMS(least mean-square) 방법에 비하여 계산량이 커서 불편하며, 접속 가능한 학습마디가 매우 많은 경우를 제외하고는 두 방식이 거의 동일한 결과를 준다.

<Step-7> 선택된 학습마디의 Playing: 콘텐츠 DB로부터 선택된 학습마디가 IF 에이전트를 통하여 학습자에게 제공되는 과정이다. 이 과정을 통하여 해당 학습마디에 대한 학습이 진행될 뿐 아니라, 그 내부의 문항SCO들에 대한 학습자의 문항반응을 얻는다.

<Step-8> 학습자 문항반응의 전달: 학습자 능력모수와 문항모수를 재추정하기 위하여, 위 과정에서 얻은 학습자 문항반응을 NSF 에이전트에 전달한다.

<Step-9> 학습자 능력모수 재추정: NSF 에이전트는 위 과정에서 얻은 학습자의 문항반응과 사용자 프로파일 DB로부터 얻은 학습자의 현 능력모수를 활용하여, 식(6)에 근거하여 학습자의 새로운 능력모수를 추정한다.

<Step-10> 문항모수 재추정: NSF 에이전트는 위 과정에서 얻은 학습자의 문항반응과 콘텐츠 DB로부터 얻은 현 학습마디의 SCO들에 대한 문항모수들을 활용하여, 식(5)에 주어진 Likelihood 함수를 최대화 하는 새로운 문항모수들을 재추정한다. 이 때, 문항모수들은 문항SCO들에 대하여 재추정되고, 학습객체SCO들은 전문가에 의하여 정해진 특성에 따라 난이도 모수를 부여받는다.

<Step-11> 재추정된 학습자 능력모수 저장: 위 과정에서 재추정된 학습자 능력모수로 사용자 프로파일 DB를 갱신한다.

<Step-12> 재추정된 문항모수 저장: 위 과정에서 재추정된 문항모수들로 콘텐츠 DB를 갱신한다.

<Step-13> 재추정된 학습자 능력모수에 따른 학습마디 선택: 이 과정은 상기 <Step-6>과 동일한 과정으로 단지 <Step-11>에서 재추정된 학습자 능력모수를 기준으로 한다는 점만 다르다. 물론 최적의 학습마디를 선택하는 기준은 식 (7)에 주어진 제공평균오류이다.

학습자가 로그인하여 맞춤형 학습이 계속되는 동안 상기 <Step-7>부터 <Step-13>까지 반복된다. 주지하는 바와 같이, 이러한 반복이 진행되면서 학습자 능력모수와 문항모수는 주기적으로 재추정된다. 이 때, 문항모수의 변화는 실제로 문항의 난이도, 변별도, 추측도 등이 변화하는 현상이라기보다는 추정상 오류가 수정되는 과정이라고 볼 수 있다. 일정 수준의 재추정이 이루어진 후로는 거의 변화가 감지되지 않을 것으로 예상된다.

한 학기 혹은 학년도가 종료되는 시점에서는 다시 오프라인 과정으로 모수들의 재추정과 학습관리를 위한 피드백 자료의 공급 등이 일어난다. 이 과정들도 그림1에서 점선으로 표시되어 있다.

<Step-14> 오프라인 모수 재추정: 모든 학습자의 문항반응, 현 능력모수, 현 문항모수 등을 활용하여, BILOG 등 IRT 프로그램으로 현재까지 제작되어 있는 문항SCO들에 대한 문항모수 $a_i, b_i, c_i, i = 1, 2, \dots, N$ 들을 재추정하고, 학습자 능력모수 $\theta_j, j = 1, 2, \dots, M$ 들을 재추정한다. 이는 차학기 혹은 차학년도의 초기에 맞춤형 학습시스템의 초기조건을 설정할 자료가 된다.

<Step-15> 피드백 정보 제공: IRT 프로그램이 제공하는 다양한 피드백 정보를 학교 현장에 피드백한다. 여기에는 학습관리를 위한 다양한 정보 즉 문항특성곡선(ICC), 검사특성곡선(TCC), 문항모수의 카이스퀘어 적합도(Goodness-of-fit), 능력 추정의 표준오차(SE), 정보함수(Information function), 진점수(TS) 등이 포함된다. 특히 진점수는 학교에서 기존의 상대평가를 대신할 수 있는 자료로 활용될 수 있다.

IV. 향후 연구 과제

본 논문에서는 학습마디(learning node) 개념을 도입하여 학습객체SCO와 문항SCO를 공존시킴으로써, 학습자 능력모수와 문항모수를 학습과정에서 수시로 재추정하여 최적의 동적 학습객체를 제공하는 개인 맞춤형 학습시스템을 구축하는

새로운 방안을 제시하였다. 이는, 기존의 학습자 선호도 및 흥미를 위주로 하는 맞춤형 개념과 반복학습 혹은 검색습관 등을 고려하는 학습시스템과는 대조적으로 학습자의 능력(ability)을 기준으로 최적의 학습객체를 동적으로 제공하는 학습시스템으로, 교육평가 분야의 최근 경향인 문항반응이론(IRT)에 근거를 둔다. 또한, 우리나라 초중고교의 정규수업을 고려하여, 학기 혹은 학년 등 일정한 기간이 끝나면 최종 자료를 추출하여 오프라인 추정을 실시함으로써 모수들을 비롯한 시스템을 재정비하고, 학습관리에 필요한 다양한 피드백 자료를 제공할 수 있도록 하였다.

본 연구는 우선적으로 단원이나 차시 아래에 수평적으로 분포된 학습마디를 갖는 교과목에 적용하는 것을 목표로 하였다. 향후 수학이나 과학 같은 계층적 분포를 갖는 학습마디도 고려되어야 하며, 수평적 분포와 계층적 분포가 혼재하는 경우에 대해서도 연구해야 할 것이다.

본 연구가 지향하는 학습시스템은 다양한 학습마디가 존재함을 전제로 하고 있으나, 학습시스템 구축 초기에는 풍부한 객체들이 확보되기 어렵다. 향후 많은 교사들과 학생들이 참여할수록 더욱 견고한 맞춤형 학습시스템이 될 것으로 기대된다. 이와 같이 풍성한 자료가 제공되면, 모수들의 변화추이나 학습과정에서 나타나는 개선점 등을 보완하는 실험을 실시할 수 있을 것으로 기대된다.

본 연구에서 피험자들의 문항반응을 분석하기 위한 도구로 활용한 것은 3-모수 로지스틱 모델이며, 모든 문항들이 일차원성(unidimensionality)과 문항독립성(local independence)을 만족한다고 가정하였다. 향후 선다형 문항 및 자유형 문항 등이 섞여 있는 평가를 이용한다면, 이들에 대한 검사동등화(test equating) 과정을 필요로 한다[13]. 이는 특히 다이나믹한 이터닝에 있어 매우 적용하기 어렵다는 점을 간과할 수 없으므로 이 부분에 대한 연구도 심도 있게 이루어져야 할 것이다.

■ 참고 문헌 ■

- [1] M. Balabanovic and Y. Shoham, "Fab : Content-based, Collaborative Recommendation," *Commun. of the ACM*, Vol.40, No.3, pp.66-72, 1997.
- [2] A. K. Papanikolaou and M. Grigoriadou, "Towards New Forms of Knowledge Communication : the Adaptive Dimensions of a Web-based Learning Environment," *Computers & Education*, Vol.39, pp.333-360, 2002.
- [3] 오용선, "개념단위 오브젝트별 분기방식을 적용한 교육용 디지털콘텐츠 및 이를 이용한 디지털콘텐츠 처리 방법," 대한민국 특허 제10-0442417호, 2004.

- [4] F. B. Baker and S. H. Kim, *Item Response Theory - Parameter Estimation Techniques*, 2nd. Ed., Marcel Dekker Inc., 2004.
- [5] 백소영, 김명, "수준별 개별학습을 지원하는 문제은행 시스템의 설계와 구현," 한국컴퓨터교육학회 논문지, 제3권, 제2호, pp.31-37, 2000.
- [6] 최숙영, 양형정, 백현기, "문항반응이론에 의한 컴퓨터 적응적 평가와 동적 학습내용 구성에 기반한 적응형 교수 시스템," 정보과학회 논문지: 소프트웨어 및 응용, 제32권, 제5호, pp.438-448, 2005.
- [7] C. M. Chen, H. M. Lee, and Y. H. Chen, "Personalized e-Learning System Using Item Response Theory," *Computers & Education*, Vol.44, pp.237-255, 2005.
- [8] C. M. Chen and L. J. Duh, "Personalized Web-based Tutoring Based on Fuzzy Item Response Theory," *Expert Systems with Applications*, Vol.34, pp.2298-2315, 2008.
- [9] W. G. Findley, "Purpose of School Testing Programs and Their Efficient Development," in *Sixty-second Yearbook of the National Society for the Study of Education*, Part II, Univ. of Chicago Press, pp.1-27, 1963.
- [10] IRT from SSI, BILOG-MG 3.0 매뉴얼.
- [11] 성태제, 문항반응이론의 이해와 적용, 교육과학사, 2001.
- [12] B. D. Wright and M. A. Stone, *Best Test Design*, Chicago: MESA press, 1979.
- [13] 황소림, "혼합 문항유형 검사의 가교문항 수에 따른 IRT 동등화 정확성 비교," *교육평가연구*, 제20권, 제3호, pp.169-193, 2007.