

# SCORM 기반의 동적인 시퀀스를 이용한 적응형 학습 시스템

이 종근<sup>†</sup> · 김형일<sup>\*\*</sup> · 김준태<sup>\*\*\*</sup>

## 요 약

정형화된 교육 절차에 따라 학습을 수행하고 종료하는 방식의 e-learning으로는 학습자의 수준에 맞는 적절한 교육을 제공하기 어렵다. 이와 같은 문제점을 해결하기 위해 SCORM에서는 학습 결과에 따라 학습 절차를 규정하는 시퀀싱을 활용하여 학습자의 수준에 맞는 적절한 교육을 제공한다. 일반적으로 시퀀싱 설계는 교수자나 학습 저작자가 담당하여 학습 프로그램을 규칙화한다. 그러나 정형화된 시퀀싱은 학습 집단이나 학습자의 특성을 반영하지 못하며, 잘못된 시퀀싱이 설계되었을 경우에 학습자들이 불필요한 재학습을 수행해야 한다. 본 논문에서는 이와 같은 문제점을 해결하기 위해 동적 시퀀싱을 적용한 학습 평가 자동화 시스템을 제안한다. 동적 시퀀싱에서는 학습자들의 평가점수가 시퀀싱에서 활용하는 기준점수에 반영되어 기준점수를 동적으로 변화시킨다. 기준점수를 동적으로 변화시킴으로 시퀀싱은 학습 집단이나 학습자들의 수준에 맞게 동적으로 변화된다. 본 논문에서는 몇 가지 실험을 통하여 제안한 동적 시퀀싱을 적용한 학습 평가 자동화 시스템이 학습 집단이나 학습자의 수준에 적합한 교육 절차를 제공함을 보였다.

키워드 : e-러닝, 스크, 시퀀싱, 동적 시퀀싱

## An Adaptative Learning System by using SCORM-Based Dynamic Sequencing

JongKeun Lee<sup>†</sup> · Hyungil Kim<sup>\*\*</sup> · Juntae Kim<sup>\*\*\*</sup>

## ABSTRACT

The e-learning system in which the learning is carried out by predefined procedures cannot offer proper learning suitable to the capability of individual learner. To solve this problem, SCORM sequencing can be used to define various learning procedures according to the capabilities of learners. Currently the sequencing is designed by teachers or learning contents producers to regularize the learning program. However, the predefined sequencing may not reflect the characteristics of the learning group. If inappropriate sequencing is designed it may cause the unnecessary repetition of learning. In this paper, we propose an automated evaluation system in which dynamic sequencing is applied. The dynamic sequencing reflects the evaluation results to the standard scores used by sequencing. By changing the standard scores, the sequencing changes dynamically according to the evaluation results of a learning group. Through several experiments, we verified that the proposed learning system that uses the dynamic sequencing is effective for providing the proper learning procedures suitable to the capabilities of learners.

Key Words : e-Learning, SCORM, Sequencing, Dynamic Sequencing

## 1. 서 론

e-learning은 콘텐츠 개발이 편리하고 자유로우며, 학습에 흥미를 느낄 수 있도록 콘텐츠를 저작할 수 있는 장점들이 있으나, 교수자가 학습자를 현장에서 직접적으로 관리할 수 없다는 단점 때문에 학습자의 학습 태도나 이해도에 대한

정확한 평가가 어렵다. 또한 선형적 학습 난이도에 따른 단계별 학습 진행 프로그램은 정형화된 학습 형태로 인하여 학습자가 지루함을 느낄 수 있다. e-learning에서 해결할 중요한 문제는 학습자의 수준에 적절한 교육 제공이며, 개인의 수준에 맞는 교육 프로그램을 생성하여 어떻게 제공할 것인가가 중요한 과제이다[8].

e-learning은 시·공간적 제약을 받지 않기 때문에 언제나 학습자에게 적합한 교육을 지원할 수 있는 장점이 있으며, 맞춤형 교육을 가능하게 한다[3]. e-learning이 활성화되면서 학습 콘텐츠와 실행 환경은 다양해져 가고 있지만,

<sup>†</sup>준 회원 : 동국대학교 대학원 컴퓨터공학과 석사과정

<sup>\*\*</sup>정 회원 : 동국대학교 컴퓨터공학과 IT분야 교수요원(교신저자)

<sup>\*\*\*</sup>정 회원 : 동국대학교 컴퓨터공학과 교수

논문접수 : 2005년 7월 6일, 심사완료 : 2006년 5월 16일

표준화가 되어 있지 않아 콘텐츠의 재사용이 어려우며, 실행 환경에 종속적인 학습 콘텐츠는 콘텐츠 저작 비용을 증가시키는 문제를 발생시킨다[5, 12, 17]. 이러한 문제를 해결하기 위하여 SCORM(Sharable Content Object Reference Model)이 개발되었으며, SCORM의 개발로 콘텐츠와 실행 환경 제작에 기준을 제시하여 콘텐츠의 공유가 가능하게 되었다[5, 15, 18, 20].

SCORM에서는 시퀀싱(sequencing)을 활용하여 학습자의 수준에 따라 교육 콘텐츠를 다르게 하는 방법을 제공하고 있으나, 현재는 모든 학습 집단에게 일률적인 시퀀싱을 적용하는 초보적인 수준이다[16]. 학습의 단계를 정의하는 모델이라 할 수 있는 시퀀싱은 교수자가 최초로 설계하기 때문에 교수자가 예상했던 것과 다른 상황이 발생할 경우 적절히 대처할 수 없다. 이러한 문제는 시퀀싱 설계 후에 시퀀싱이 고정되기 때문에 발생하는 것이며, 고정된 시퀀싱의 문제를 해결하기 위해서는 학습 집단이나 학습자들의 수준이나 능력에 맞게 시퀀싱이 동적으로 변화될 수 있도록 시퀀싱을 설계할 수 있어야 한다.

본 논문에서는 이와 같은 문제점을 해결하기 위해 동적 시퀀싱(dynamic sequencing)을 적용한 학습 평가 자동화 시스템을 제안한다. 학습 단계 측면에서 일반적인 시퀀싱은 학습자의 평가점수와 교수자가 설계한 기준점수를 비교하여 기준점수 이상의 평가점수를 획득한 학습자에게만 다음 단계의 교육을 이수할 수 있는 권한을 부여한다. 이러한 선형적 방식을 취하는 고정화된 시퀀싱은 교수자가 최초로 설계한 학습 프로그램 기준에 의해 모든 학습 집단들에게 일괄 적용되나, 본 논문에서 제안하는 동적 시퀀싱은 학습 집단의 수준과 능력에 맞도록 기준점수를 학습 집단이나 학습자의 평가 값에 따라 자동으로 변화시켜 학습 집단에 맞는 기준점수를 동적으로 생성한다. 본 논문에서 제안하는 동적 시퀀싱 방법은 학습자의 평가점수가 기준점수를 변화시키는 것으로서, 초기의 시퀀싱을 위한 기준점수가 지나치게 높거나 낮게 설정되더라도 학습이 진행되면서 적절한 기준점수가 설정되고 이에 따라 적절한 시퀀싱이 이루어지도록 하는 것이다. 학습 시스템에 동적 시퀀싱을 적용함으로써 학습 집단의 수준에 맞는 교육이 가능해진다.

본 논문에서 제안한 동적 시퀀싱은 온라인 학습 시스템에 적용되면 실시간으로 학습자의 학습 평가를 수행할 수 있으며, 학습 집단의 특성에 적합한 기준점수를 동적으로 변화시킴으로써 학습 집단의 특성에 맞게 재학습을 수행하여 불필요한 재학습을 제거할 수 있다. 또한 본 논문에서 제안한 동적 시퀀싱은 기준점수 변화에 표준정규분포를 적용하여 우수 학습자나 열등 학습자들을 추출할 수 있기 때문에 학습자들의 능력에 맞도록 학습 집단을 재구성할 수 있다.

## 2. 관련 연구

e-learning의 표준에 대한 필요성이 높아지면서 미국을 중심으로 표준화 작업이 진행되고 있다. 표준화 작업에 주

도적인 역할을 담당하는 곳은 미국의 국방부와 백악관 과학 기술정책위원회(White House Office of Science and Technology Policy)가 출자해 1997년에 만든 ADL(Advanced Distributed Learning)이다. ADL은 교육용 콘텐츠의 재사용성을 높이고, 개인별 맞춤 교육을 위해 SCORM을 제안했다[5]. ADL에서 만든 SCORM은 웹을 기반으로 하며, 교육용 콘텐츠의 재사용성을 높이기 위한 콘텐츠 객체의 참조 모델이다. SCORM은 IMS(Industrial Management System), AICC(Aviation Industry Computer Base Training Committee), IEEE LTSC(Learning Technology Standards Committee) 등의 기관이 개발하고 있는 표준을 통합하여 개발되고 있다. 현재, SCORM 자체는 표준이 아니지만, 다른 기관들의 스펙과 표준들을 통합, 테스트, 보완함으로써 강력한 참조 모델을 제시하고 있다. 따라서 SCORM은 향후 e-learning 표준의 유력한 후보이며, 거의 사실상의 표준안으로 자리를 잡아가고 있다.

e-learning은 웹 기반 교육 측면에서 ITS(Intelligent Tutoring Systems)를 포함한다. ITS는 e-learning이 활성화되기 이전부터 생성된 오프라인을 포함한 지능적 교육 시스템이다. 그러나 ITS는 학습 자원이 학습 시스템에 종속된다는 단점을 가지고 있다. SCORM과 ITS는 실시간으로 개별화된 맞춤형 콘텐츠를 제공한다는 것과 대화와 질의응답이 가능하다는 점에서 공통적인 요소를 갖는다. 그러나 ITS는 학습 자원들이 시스템에 귀속되기 때문에 재사용성과 독립성이 떨어진다는 점에서 SCORM과 다르다. 또한 ITS는 학습자와 교수자 사이의 세부적인 연결구조가 언급되나, SCORM은 상위 수준의 연결구조만을 제공하여 확장성이 좋다[10]. ITS의 단점을 보완하기 위해 Jacqueline 등[11]은 SCORM에서 정의한 시퀀싱을 ITS에 적용할 수 있는 상위 수준의 프로토타입 모델인 SITA(simulation-based intelligent training and assessment)를 제안하였으며, 현재 SCORM의 구조를 ITS에 결합하기 위한 다양한 연구가 수행되고 있다.

학습 객체에 대한 시퀀싱을 결정할 경우 학습자의 학습 능력이나 학습 객체의 난이도에 따라 다양한 시퀀싱이 존재함으로써 매우 복잡한 시퀀싱들이 형성될 수 있으며, 이러한 복잡한 시퀀싱은 콘텐츠 개발자가 추가적인 학습 객체를 생성할 때 어려움을 발생시킨다. 이러한 학습 객체 시퀀싱의 복잡성을 해결하기 위하여 Lin 등[13]은 petri net을 적용한 바 있다. Petri net은 학습 객체를 노드로 정의하고 학습 경로를 링크로 정의하여 시퀀싱을 도식화하는 방법이다. 학습 객체와 학습 경로를 도식화함으로써 학습 객체들간의 연결 관계가 정의되어 시퀀싱의 축약과 확장이 용이해지는 장점이 있다. 그러나 학습 객체에 대한 시퀀싱을 구조화하기 위해서 다량의 학습 객체와 학습 정보가 필요하다. petri net을 활용하여도 시퀀싱이 고정되면 학습 집단의 학습 능력을 고려한 시퀀싱은 설계될 수 없다.

학습 집단의 학습 능력 향상을 위해 Chang 등[4]은 SCORM에 Petri net을 적용한 DCPN(distance-learning color petri net) 모델을 제안하고, 학습 능력 향상을 위해 협동적

학습(collaborative learning)을 DCPN에 적용하였다. 협동적 학습을 위해 학습자들은 학습을 수행하기 전에 테스트를 거친 후 학습 집단에 소속되며, 소속된 학습 집단에는 팀 단위 시퀀싱에 대한 학습 목표뿐만 아니라, 팀원들의 학습 목표도 각각 주어진다. 이와 같은 DCPN에 협동적 학습을 적용함으로써 학습 능력 향상에는 조력할 수 있으나, 고정된 시퀀싱이 적용됨으로 교수자의 오류에 의한 잘못된 시퀀싱 설계에 대해 대응하지 못하는 단점이 있다. 또한 협동적 학습을 수행하기 위해서는 다수의 학습자들이 존재하여야 하기 때문에 학습 시스템의 초기에는 협동적 학습의 특성을 살릴 수 없는 단점이 존재한다.

Carnegie Mellon 대학의 LSAL(Learning Systems Architecture Lab)은 교육을 위한 인터넷 기반 기술을 설계 및 생성하는 연구를 하고 있으며, 현재 SCORM 규격 책정과 활용 방안에 대한 프로젝트를 진행하고 있다. LSAL는 Carnegie Mellon 대학이 주관하고, ADL, Cisco, Click2Learn, IBM, Microsoft, British Open 대학 등이 참여하고 있다. LSAL에서는 개인화되고 적응적인 시퀀싱의 중요성을 인식하여 현재 지속적인 연구를 수행하고 있는 중이며, 개인화 시퀀싱에 대한 연구가 진행되기 전에는 CLEO(Customized Learning Experiences Online)[19] 프로젝트를 진행한 바 있다. CLEO에서는 개인화된 학습 객체 집합을 생성하고 구성하기 위한 개방형 표준을 정의하였으며, 이 표준은 현재 SCORM의 시퀀싱의 코스 구조 형식(course structure format)에 대한 가이드라인을 제시하였다[20].

Hasebrook[7]은 웹 기반 교육 시스템에서 학습자의 학습 능력 향상을 위해 교수자가 직접 시스템에 개입하는 경우 교육비용이 크게 증가된다는 단점을 해결하기 위해 한정된 부분만을 교수자가 담당하고, 전체적인 학습 흐름은 자동화된 코스 시퀀싱으로 해결하는 연구를 하였다. Helic 등[8,9]은 자동화 코스 시퀀싱을 위해 학습자들의 프로파일과 교수자들의 지도법을 이용한 Virtual Classroom을 제안하였다. Virtual Classroom에서는 이전 수업들에서 교수자가 적용한 지도 방법을 학습자의 프로파일과 함께 데이터베이스화하여 새로운 수업에서 발생하는 상황(질의, 학습 코스 변경 등)에 이전의 지도 방법과 학습자의 성향을 활용하여 대처한다. 이러한 경우 과거의 유사한 학습자들의 상황을 추출하기 위해 협동적 필터링(collaborative filtering)을 적용한다. 협동적 필터링은 특정 객체에 나타나지 않은 속성값에 특정 객체와 유사도가 높은 객체들의 속성값을 적용하는 방법론을 제시한다. 교수자의 지도 방법이나 학습자의 성향을 이용하여 학습 코스를 자동화하기 위해서는 많은 지도 방법이 축적되어 있어야 하고, 학습자들의 성향 분석을 위해서도 많은 학습자가 존재하여야 한다는 단점이 있다.

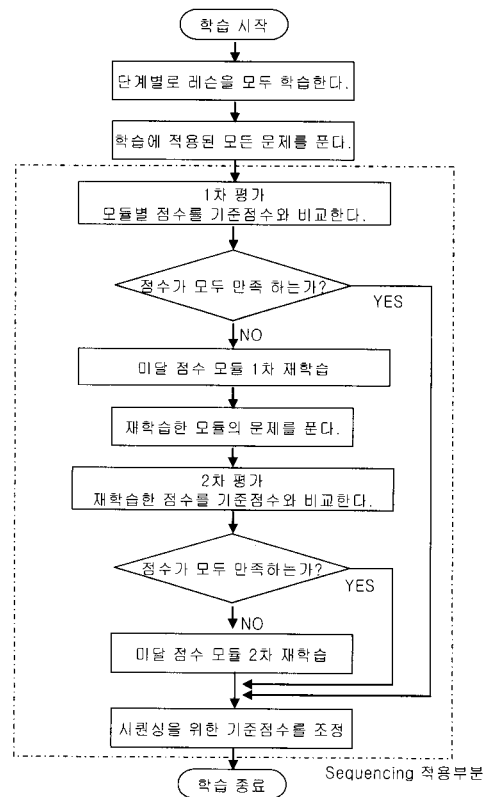
본 논문에서 제안하는 동적 시퀀싱은 LSAL의 개인화 시퀀싱에 관한 연구와 Virtual Classroom에서의 자동화 코스 시퀀싱과 그 개념에서 유사하나, 학습 집단의 평가점수에 따라 기준점수를 자동적으로 변화시킴으로써 동적으로 시퀀싱을 변화시킨다는 것에 차이점이 있다.

### 3. 동적인 시퀀싱을 적용한 학습 시스템

#### 3.1 학습 시퀀싱의 설계

학습 시스템이 발전함에 따라 학습 모듈 혹은 레슨별로 학습자의 수준을 평가하여 필요하면 재학습을 수행하는 등 학습 과정을 달리 할 수 있는 시스템이 개발되고 있다. 그러나 기존의 시스템들은 처음 학습 과정을 설계 할 때에 만들어진 학습자의 평가 기준이 고정되어 있기 때문에 초기 설계가 잘못되었다든지 혹은 학습 집단의 수준이 예상과 다른 경우에 학습 효율이 저하되는 문제가 발생할 수 있다. 예를 들어 평가 문제가 학습 집단의 수준에 비하여 너무 어렵게 만들어진 경우에는 대부분의 학습자가 반복적으로 재학습을 수행하게 된다. 본 논문에서는 학습자들이 학습을 수행하면서 평가 결과에 따라 자동적으로 평가 기준이 달라지도록 학습 시퀀싱을 설계하여 이러한 문제를 해결하는 방법을 제안한다.

기본적인 학습 시퀀싱은 학습, 평가, 재학습의 형태를 취하며, 재학습의 횟수가 여러 번일 수도 있고, 재학습 대상을 세분하여 부분적인 재학습을 수행하도록 설계할 수도 있다. 학습 시스템에서 활용한 학습 콘텐츠는 한 개 이상의 학습 모듈로 구성되며, 각 학습 모듈은 다시 한 개 이상의 레슨으로 구성된다. 본 논문에서는 학습 모듈에 포함된 레슨들을 학습한 뒤 학습 모듈 단위로 평가를 수행하며, (그림 1)과 같은 학습 시퀀싱을 기반으로 동적인 시퀀싱을 설계한다. (그림 1)의 학습 시퀀싱에서는 학습 모듈별로 재학습을 실



(그림 1) 학습 시퀀싱

시하며, 재학습 횟수는 2회까지로 제한한다. 학습자는 먼저 기본적인 학습이 이루어진 후에 1차 평가를 하여 정해진 기준점수 이상이면 해당 학습 모듈을 이수(통과)하게 되고, 기준점수에 미달되면 미달된 학습 모듈에 대해 재학습을 수행한다. 재학습 후 2차 평가를 하여 2차 평가에서도 기준점수에 미달되면 마지막으로 3차 학습을 수행하고 전체 학습을 종료시킨다.

본 논문에서 제안하는 동적인 시퀀싱 방법은 평가 단계에서 이용하는 기준점수를 학습자들의 평가점수에 따라 자동적으로 변화시키는 것이다. 즉, 학습자의 평가점수가 기준점수보다 높으면 기준점수를 상향 조정하고, 기준점수보다 낮으면 기준점수를 하향 조정한다. (그림 1)에서 최종 단계에 있는 기준점수 조정 부분이 그러한 역할을 하는 단계로써 기준점수의 조정은 1차 평가에서 통과한 학습자의 경우에는 1차 평가점수, 미달한 학습자의 경우에는 2차 평가점수를 누적하여 평균하거나, 표준정규분포를 적용함으로써 이루어진다. 이와 같이 기준점수 조정을 수행하면 학습 집단의 수준에 맞도록 학습 시퀀스가 자동적으로 조정된다.

3.2 동적 시퀀싱을 위한 평균 기준점수 조정

본 논문에서 제안하는 동적 시퀀싱을 위하여 평균을 적용한 기준점수를 조정하는 과정은 다음과 같다. 학습 통과 여부를 결정하는 현재의 기준점수를  $S_{standard}$ , 현재 학습자의 1차 평가점수를  $S_1$ , 2차 평가점수를  $S_2$  라고 하자. 현재까지의 학습자 수는  $N$ 이고  $N_{max}$  는 평균 기준점수 산출을 위한 최대 집단의 크기로서, 조정되는 기준점수는 최대 이전  $N_{max}$  명의 학습자의 평가점수를 기준으로 하도록 한다. 기본적으로 학습자의 평가점수는 기준점수에 누적되어 기준점수를 변화시키게 된다. 이때 예외적으로 너무 높거나 낮은 점수가 기준점수 조정에 큰 영향을 주는 것을 방지하기 위하여 기준점수에 누적되는 점수 폭은 현재 기준점수의  $\pm(a * 100)\%$  (단,  $0 \leq a \leq 1$ )로 제한한다. 조정되어 누적되는 점수를  $S_{adjusted}$ ,  $N$  명의 총 누적 점수를  $ACC$ 라고 하자. 초기의 총누적점수  $ACC$ 와 기준점수  $S_{standard}$ 는 모두 학습 시퀀싱 설계시 지정된 기준점수에서 출발하고, (그림 2)와 같이 조정된다. 여기에 나타낸 (그림 2)는 (그림 1)의 “시퀀싱을 위한 기준점수를 조정”에 해당한다.

```

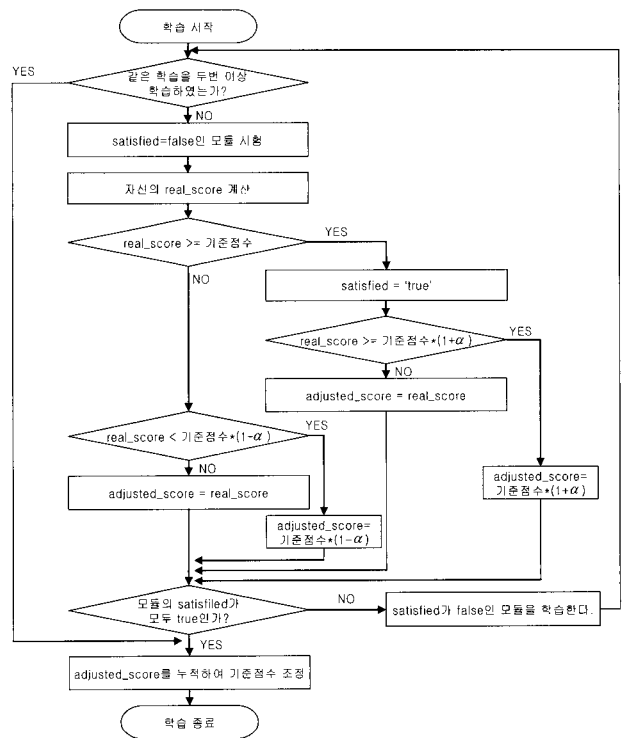
if (  $S_{standard} \leq S_1$  ) // 학습자는 1차 평가를 통과
 $S_{adjusted} \leftarrow \min ( S_1 , S_{standard} * (1+a)$ 
if (  $S_1 < S_{standard}$  ) // 학습자는 1차 평가에 실패
if (  $S_{standard} \leq S_2$  ) // 학습자는 2차 평가에 통과
 $S_{adjusted} \leftarrow \min ( S_2 , S_{standard} * (1+a)$ 
else // 학습자는 2차 평가에 실패
 $S_{adjusted} \leftarrow \max ( S_2 , S_{standard} * (1-a)$ 
if (  $N < N_{max}$  )  $N = N + 1$ 
 $ACC \leftarrow \text{sum of last } N - 1 \text{ scores}$ 
 $ACC \leftarrow ACC + S_{adjusted}$ 
 $S_{standard} \leftarrow \frac{1}{N} ACC$ 
    
```

(그림 2) 평균을 적용한 기준점수 조정 방법

즉, 1차 평가를 통과하여 학습이 종료되는 학습자의 평가 점수는 기준점수의  $\pm(a * 100)\%$  이내의 점수로 조정되어 총누적점수에 누적되고, 1차 평가에 실패하여 재학습을 수행하는 학습자는 2차 평가점수를 마찬가지로 조정하여 누적한다. 학습자의 평가 후 기준점수는 변경된 총누적점수의 평균으로 조정되어 현재 학습자의 평가결과가 기준점수를 변경시키게 된다. 예를 들어  $N = N_{max} = 10$  이고, 기준점수는  $S_{standard} = 60$ , 1차 평가점수  $S_1 = 40$ , 2차 평가점수  $S_2 = 45$  라면,  $a = 0.2$ 를 적용하는 경우  $S_{adjusted} = \max(45, 60 * 0.8) = 48$ 이 된다. 따라서 지난  $N - 1$  개의 누적점수가  $ACC = 540$  이라면 새로운 기준점수는  $S_{standard} = 1/10 * (540 + 48) = 58.8$  이 된다.

동적 시퀀싱의 핵심인 기준점수의 조정 시점은 학습 콘텐츠를 모두 학습하고 그에 대한 학습 평가를 마친 후에 수행된다. 만약 학습 콘텐츠가 한 가지 이상의 평가 단계를 포함하는 경우에는 모든 평가를 마칠 때까지 각 평가 단계의 값을 누적한 뒤에 하나의 값으로 처리하여야 한다.

(그림 3)에 본 논문에서 사용한 동적 시퀀싱 과정을 순서대로 나타내었다. 학습 콘텐츠에 속하는 모든 학습 모듈들에 대하여 학습 모듈 만족 여부를 데이터베이스에 ‘satisfied’ 값으로 각각 기록한다. ‘satisfied’ 값은 초기에 false로 지정되어 학습과 평가를 수행한 후 평가점수가 기준점수 이상이 되면 true가 된다. 학습 평가 후 학습자의 평가점수와 기준점수에 누적될 점수는 각각 ‘real\_score’와 ‘adjusted\_score’에 저장된다. 학습 평가 후 학습 시스템은 학습자가 학습을 건너뛰거나 기준점수에 미달된 학습 모듈들의 레슨을 다시 시작하고, ‘satisfied’가 false인 학습 모듈의 학습이 모두 종



(그림 3) 평균 기준점수가 적용된 동적 시퀀싱

료되면 학습자는 해당 학습 모듈에 대한 평가 문제를 다시 풀게 된다. 최종적으로 학습자가 모든 학습 모듈을 이수했을 때 기준점수를 조정하고 학습을 종료한다.

### 3.3 동적 시퀀싱을 위한 표준정규분포 기준점수 조정

본 논문에서는 동적 시퀀싱 적용시 학습 저작자나 교수자가 기준점수를 활용할 때 평균과 표준정규분포를 선택적으로 이용할 수 있도록 설계하였다. 표준정규분포를 기준점수로 활용하면 전체 학습 집단에서 일부 학습 집단만 추출하기에 용이하다. 예를 들면, 임의의 학습 집단에서 상위 10%에 해당하는 학습자들만을 추출하여 우수 집단에 편입시키려 할 경우, 평균만을 활용하여 상위 10%에 해당하는 학습자들을 추출하기 어렵다. 만약, 일부 학습자들만을 추출할 수 있다면 학습자들의 학습 등급 조정이나 재교육에 효과적으로 활용될 수 있다. 본 논문에서 제안한 동적 시퀀싱에서는 일부 학습자들만 추출하기 위해 표준정규분포를 기준점수에 적용할 수 있도록 하였다.

평균이  $\mu$ , 분산이  $\sigma^2$ 일 경우, 정규확률밀도함수를  $N(\mu, \sigma^2)$ 로 표현할 수 있으며, 이것을 식으로 나타내면 식 (1)과 같다. 정규확률밀도함수는 평균과 표준편차에 의해 결정되므로 정규분포는 다양한 형태로 나타나게 되어 확률을 계산하기 어렵다는 단점이 있다. 표준정규확률밀도함수를 활용하면 이러한 문제를 해결할 수 있으며, 표준정규확률밀도함수의 식은 식 (2)와 같다. 표준정규확률밀도함수가 나타내는 표준정규분포는 평균과 표준편차를 0과 1로 결정하여 자료를 표준화한다.

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, -\infty < x < +\infty \quad (1)$$

$$f(Z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}Z^2}, -\infty < Z < +\infty \quad (2)$$

정규분포는 평균과 표준편차에 따라 다양한 모양을 나타내기 때문에 서로 다른 모양의 두 분포를 비교하거나 면적의 크기를 계산하여 확률을 알아내기 어렵다. 이것을 해결하기 위해서는 정규분포를 표준화할 필요가 있으며, 자료를 표준화하는 방법은 평균  $\mu=0$ , 표준편차  $\sigma=1$ 이 되도록 하는 것이다. 표준화된 정규분포를 표준정규분포(또는 Z분포)라 한다.

본 논문에서 제안한 동적 시퀀싱을 위해 표준정규분포 기준점수를 조정하는 과정은 다음과 같다. 학습 집단에서 일부 학습자들만을 선택하기 위한 영역(예: 상위 10%, 하위 10% 등)을 결정하는 영역기준값을  $\alpha$ , 영역기준값  $\alpha$ 에 해당하는 Z값을  $Z_\alpha$ , 최초의 기준점수로 활용될 평가점수는  $S_0$ , 학습 통과 여부를 결정하는 현재의 기준점수를  $S_{standard}$ , 현재 학습자의 1차 평가점수를  $S_i$ , 2차 재평가점수를  $S_r$ 이라고 하자. 현재까지의 학습자 수는  $N$ 이고  $N_{max}$ 는 기준점수 산출을 위한 최대 집단의 크기로서, 조정되는 기준점수는 최대

이전  $N_{max}$ 명의 학습자의 평가점수를 기준으로 하도록 한다. 기본적으로 학습자의 평가점수는 Queue에 누적되며, Queue의 표준정규분포에 의해 기준점수가 변화된다. 이때 학습자가 추가될 때마다 표준정규분포를 계산을 위해 Queue에 저장되어 있는 평가점수들을 이용하여 평균  $S_{mean}$ 과 표준편차  $S_{deviation}$ 을 계산하여 다음 학습자를 위해 새로운 기준점수를 생성한다. 2차 평가가 수행될 경우 너무 높거나 낮은 2차 평가점수가 기준점수 조정에 큰 영향을 주는 것을 방지하기 위하여 Queue에 누적될 평가점수는 1차 평가점수와 2차 평가점수의 최소값과 평균값을 활용한다. 표준정규분포를 적용한 기준점수 조정 방법을 (그림 4)에 나타내었다.

표준정규분포를 기준점수로 활용하여 상위 10%의 학생들만을 추출하는 예를 들면 다음과 같다. 학습자들의 평균  $S_{mean}$ 이 85점이고 표준편차  $S_{deviation}$ 가 10이라고 가정할 후, 상위 10% ( $\alpha=10$ )의 학생들을 추출하기 위한 기준점수는 다음과 같이 계산된다. 표준정규분포는 평균을 기준으로 대칭되므로 상위 10%는 확률이  $0.4(=0.5-0.1)$ 인 지점이 되며, 0.4에 해당하는 Z값  $Z_\alpha$ 는 1.28이다.  $Z_\alpha = \frac{X-\mu}{\sigma}$ 에 의해 X는 97.8이 되어 상위 10%에 해당하는 기준점수는 97.8점이 된다.

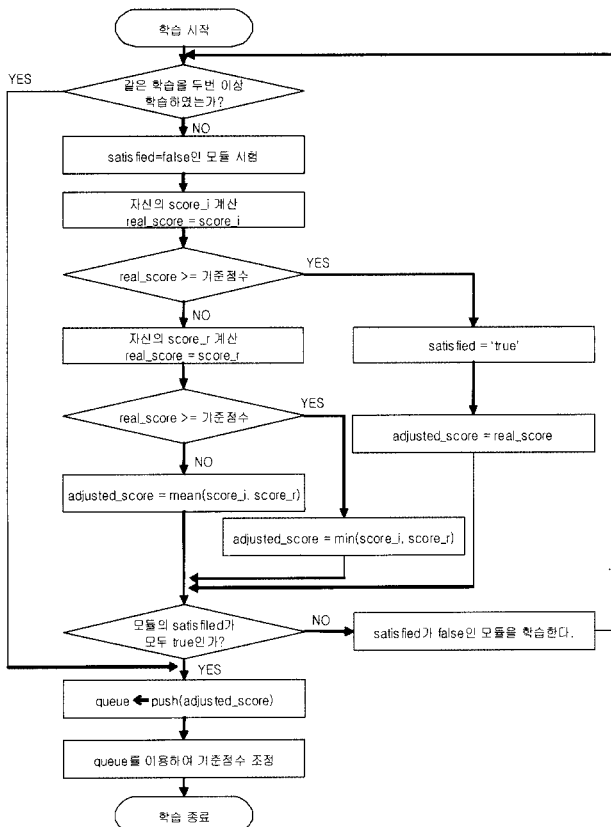
(그림 5)에 본 논문에서 표준정규분포 기준점수를 사용한 동적 시퀀싱 과정을 순서도로 나타내었다. 각 학습 모듈별로 학습 만족 여부는 데이터베이스에 'satisfied' 값으로 기록된다. 'satisfied' 값은 초기에 false로 지정되어 학습과 평가를 수행한 후 평가점수가 기준점수 이상이 되면 true가 된다. 학습 평가 후 학습자의 1차 평가점수와 2차 평가점수는 각각 'score\_i'와 'score\_r'에 저장되고, 'queue'에 입력될 학습자의 평가점수는 'adjusted\_score'에 저장된다. 학습 평가 후 학습 시스템은 학습자가 학습을 건너뛰거나 기준점수에 미달된 학습 모듈의 레슨을 다시 시작하고, 'satisfied'가 false인 학습 모듈의 학습이 모두 종료되면 학습자는 해당 학습 모듈에 대한 평가문제를 다시 풀게 된다. 기준점수 조정시 예외적으로 너무 높거나 낮은 점수가 기준점수 조정에 큰 영향을 주는 것을 방지하기 위하여 'queue'에 입력될 최

```

S_standard ← S_0
for(i = 1, N < N_max, i++)
  Z_α ← select(α) // 표준정규확률밀도함수에 의한 Z값
  if (S_standard ≤ S_i) // 학습자는 1차 평가를 통과
  if (S_i < S_standard) // 학습자는 1차 평가에 실패
    if (S_standard ≤ S_r) S_i ← min(S_i, S_r)
  else S_i ← mean(S_i, S_r)
  N = i
  Queue ← S_i
  S_mean ← mean(Queue)
  S_deviation ← deviation(Queue)
  S_standard ← S_deviation * Z_α + S_mean

```

(그림 4) 표준정규분포를 적용한 기준점수 조정 방법

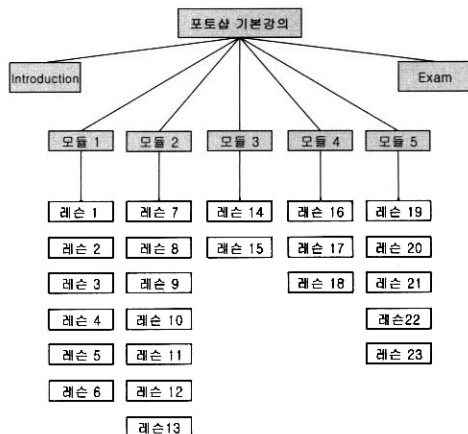


(그림 5) 표준정규분포 기준점수가 적용된 동적 시퀀싱

중 평가점수를  $\text{mean}(\text{score}_i, \text{score}_r)$ 과  $\text{min}(\text{score}_i, \text{score}_r)$ 로 제한한다.

### 3.4 동적인 시퀀싱을 적용한 학습 시스템의 구현

본 논문에서 제안한 동적 시퀀싱을 구현하고 실험하기 위하여 포토샵 교육을 위한 학습 평가 자동화 시스템을 구현하였다. 시스템 구현은 ADL에서 제공하는 'Sample RTE 1.3' 학습 시스템 실행 환경과 포토샵 학습 콘텐츠를 토대로 실험에 적합하도록 수정하여 제작하였다. 포토샵 학습 콘텐츠는 5개 학습 모듈, 평가 문제 집합으로 구성되며, 각 학습

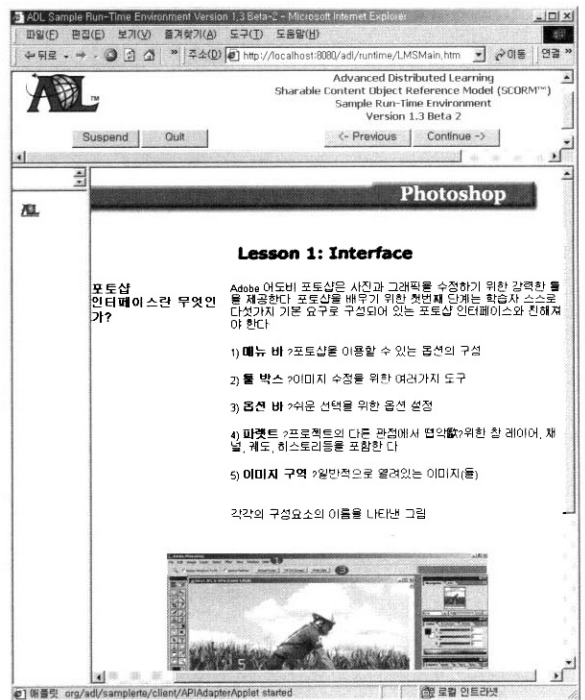


(그림 6) 학습 콘텐츠 계층도

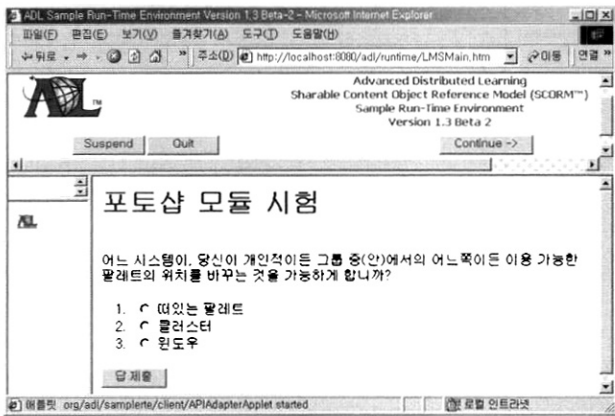
모듈은 또다시 여러 개의 레슨 파일들로 구성된다. 그리고 레슨 파일들에는 총 218개의 이미지 파일과 강의 자료가 포함되어 있다. 그 외에도 콘텐츠 패키지를 설명하고 있는 Manifest 파일과 메타데이터의 XML 파일들이 존재한다.

시퀀싱의 설계는 Manifest 파일의 구성 정의 부분에서 작성되며, 기준점수 미달에 따른 반복 학습은 최대 3회로 횟수를 제한하였다. 평가 문제 집합은 각 학습 모듈에 대한 평가를 위해 10개씩의 평가 문제를 포함하고 있다. (그림 6)는 본 논문의 실험을 위하여 구성된 포토샵 학습 콘텐츠의 계층도이다.

본 논문에서 구현한 학습 시스템은 ADL에서 샘플로 제공하는 것을 기반으로 본 논문에서 제안한 동적 시퀀싱에 적합하도록 수정하여 구현하였다. 학습 시스템은 크게 관리자 와 사용자 영역으로 나뉜다. 관리자는 시스템의 총괄 책임자로서 시스템에서 행할 수 있는 모든 권한을 가지고 있다. 관리자만이 행할 수 있는 기능으로 '학습 가져오기'는 Zip으로 패키징 되어 있는 학습 데이터를 학습 시스템으로 입력하는 기능이고, '학습 삭제'는 입력된 학습 데이터를 삭제하는 기능이다. '사용자 추가 및 삭제'에서 다른 관리자, 교수, 학습자를 추가하거나 삭제 할 수 있고, '데이터베이스 삭제'에서 학습자들의 학습 진행 상태를 삭제 할 수 있다. '전체 목표 관리'에서 학습자의 학습 상황을 기록하고, 등록 되어 있는 학습을 관리한다. '학습 가져오기'에서는 학습의 이름과 ZIP 파일의 경로를 입력하여 학습 데이터를 시스템으로 가져온다. 학습 데이터를 가져오면 가져오는 순서에 따라 학습 데이터에 대한 폴더가 생성되며, 이 폴더에 해당 학습 데이터의 패키지가 풀려 저장된다.



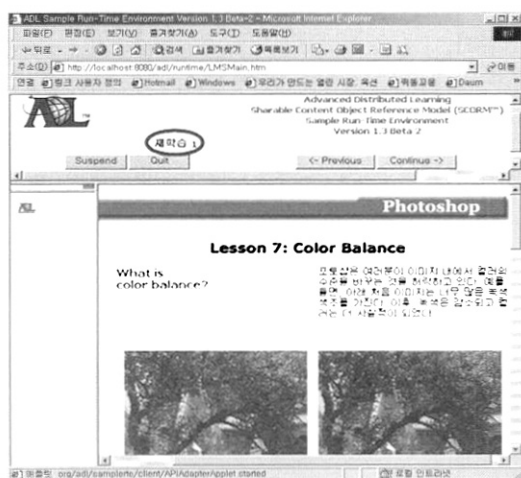
(그림 7) 학습 시작 화면



(그림 8) 학습 평가 화면

학습자는 사용자 인터페이스를 통하여 자신이 학습하고자 하는 학습을 등록 하고, 등록된 학습을 볼 수 있으며, 비밀번호 변경 작업이 가능하다. '학습 등록'에서는 사용자가 원하는 학습을 등록할 수 있고, 등록할 수 있는 학습은 관리자가 입력한 학습 중에서 선택할 수 있다. '등록한 학습 보기'을 통해 학습자는 등록된 학습 코스를 볼 수 있으며, '학습명'을 클릭하면 학습이 시작된다. 학습을 중간에서 멈추었다면 멈추었던 부분부터 다시 학습이 수행 되며, 학습을 수행하면서 문제를 제공받아 테스트를 할 수 있다. (그림 7)과 (그림 8)은 각각 학습 화면과 평가 화면의 예이다.

본 논문에서 제안한 학습 시스템은 학습자의 평가점수가 기준점수보다 낮으면 부족한 학습 모듈에 대해 재학습을 수행하고, 재학습 후에 치른 시험에서도 기준점수보다 낮다면 최종 재학습을 수행하도록 하였다. (그림 9)는 재학습에 해당하는 화면으로 기준점수에 미달된 두 번째 학습 모듈을 재학습하는 과정을 나타낸 그림이다. 시험 점수가 기준점수보다 높으면 학습을 종료하고, 학습이 종료된 후 학습자의 평가점수는 기준점수를 조정하는데 활용된다. 종료된 학습은 다시 학습할 수 없으며, 다시 학습 하려면 완료된 학습을 삭제한 후 다시 해당 학습을 등록하여 학습 하여야 한다.



(그림 9) 재학습 화면

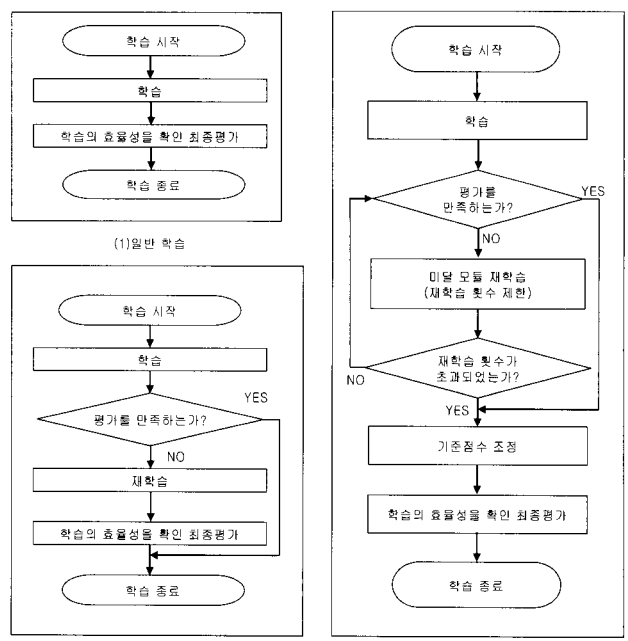
#### 4. 성능 평가

본 논문에서 제안한 동적인 시퀀스를 적용한 학습 시스템이 학습에 적절한지 평가하기 위해 실제 학습 집단을 이용한 실험과 가상의 학습 집단을 이용한 시뮬레이션을 수행하였다. 비교 실험에 사용된 학습 시스템들은 시퀀싱이 없는 일반 학습 시스템, 기본적인 시퀀싱을 적용하여 반복 학습이 가능한 학습 시스템, 그리고 본 논문에서 제안한 동적 시퀀싱이 적용된 동적 학습 시스템이다.

##### 4.1 실제 학습 집단에서의 실험

본 실험에서는 실제 학습자들을 대상으로 학습 수준에 대한 실험을 수행하여 제안한 학습 시스템의 성능을 측정하였다. 평가 대상은 컴퓨터학원에 다니는 고학년 초등학생부터 중학생까지이며, 평가 대상에 소속된 학생들은 컴퓨터에 대한 기초적인 지식을 소유하고 있다. 평가 집단은 학습 능력의 정도에 따라 3집단으로 나누었으며, 각 집단에 소속된 인원은 20명으로 제한하였다. 재학습에 수행되는 시간을 측정하기 위해 학습 수행 과정에서 발생하는 학습 시간은 제한하지 않았으며, 실험에 사용한 학습 과목은 포토샵이다.

본 논문에서 제안한 학습 시스템의 실험에 활용한 모델은 총 세 가지이다. 첫 번째 학습 시스템은 일반적인 학습 방법이 적용된 것으로 한 번의 학습이 수행된 후 학습 평가가 수행된다. 이 시스템은 시퀀싱이 없는 온라인 학습 시스템의 초기 모델이다. 두 번째 학습 시스템은 고정된 시퀀싱 방법이 적용된 것으로 학습자의 평가점수가 고정된 기준점수에 미달하게 될 경우 재학습을 수행하고, 재학습이 종료된 후 마지막 최종 평가를 재수행하는 방식을 취한다. 이 시스템은 반복 학습을 지원하는 선형적 방식의 학습 시스템



(2) 반복 학습 (고정화된 시퀀싱)

(3) 동적 학습

(그림 10) 실험에 사용된 세가지 학습 시스템

으로 e-learning이 부각되면서 근래에 적용되고 있는 시퀀싱 방법이다. 시퀀싱을 위한 기준점수는 60점으로 하였다. 마지막으로 세 번째 학습 시스템은 본 논문에서 제안하는 동적인 시퀀싱을 적용된 학습 시스템으로 학습자의 평가점수가 기준점수를 변화시키며, 새로운 학습자에게는 변화된 기준점수가 적용되는 방식을 취한다. (그림 10)에 실험에 사용된 세 가지의 학습 시스템의 학습 방법을 나타내었다.

<표 1>은 세가지 학습 시스템에서의 평균 학습시간과 평가점수, 재학습률 등을 나타낸다. 첫 번째 학습 시스템의 경우 반복 학습이 배제되어 평균 학습 시간이 37분으로 가장 짧았으나, 학습자들이 취득한 평가점수의 평균은 49점으로 다른 학습 시스템에 비해 매우 낮은 평가점수를 나타냈다. 이와 같은 결과는 일반적인 고정된 학습 방법은 학습 집단의 특성에 관계없이 일률적인 학습이 진행되므로 높은 학습 효과를 얻지 못한다는 것을 보여준다. 분당 취득 점수는 일반 학습 시스템이 1.32점으로 반복 학습이 적용된 학습 시스템보다 0.03점 높았으며, 동적 시퀀싱이 적용된 학습 시스템보다는 0.18점 낮았다.

두 번째 학습 시스템은 고정된 시퀀싱이 적용되어 한 번의 학습 후 평가점수가 기준점수에 미달할 경우 재학습을 수행하는 것으로서, 학습시간은 일반적인 학습 방법보다 오래 걸렸지만, 평균 평가점수는 71점을 나타내어 일반적인 학습 시스템보다 22점이 높았다. 이와 같이 평가점수가 높은 차이를 나타내는 것은 학습자의 학습 능력 평가에 따라 학습 시스템이 학습자의 부족한 학습을 메우기 위해 반복 학습을 통하여 학습자의 수준을 향상시키기 때문이다. 이러한 결과를 보면 기본적인 시퀀싱에 의한 단순 반복 학습도 학습자의 수준을 향상시키는데 효과가 있음을 알 수 있다. 분당 취득점수는 1.29점을 나타내어 일반적인 학습 방법에 비해 0.03점 낮았다.

세 번째 학습 시스템은 본 논문에서 제안한 동적 시퀀싱이 적용된 학습 시스템으로서 평균 학습 시간은 58분으로 고정된 시퀀싱이 적용된 학습 시스템 보다 약간 많게 나왔지만, 재학습 성과는 다른 학습 시스템들에 비해 우수하게 나타났다. 동적 시퀀싱이 적용된 학습 시스템에서 평균 평가점수는 87점을 나타내어 고정된 시퀀싱을 적용한 학습 시스템에 비해 16점, 일반 학습 시스템에 비해서는 38점 높게 나타났다. 분당 취득점수도 1.5점으로 일반 학습 시스템보다 0.18점, 고정된 시퀀싱의 반복 학습 시스템보다 0.21점(16%) 높게 나타났다. 재학습률은 67%로서 반복 학습 시스템에 비해 2% 정도의 작은 차이만을 나타냈다. 고정된 시퀀싱이 적용된 학습 시스템과 동적 시퀀싱이 적용된 학습 시스템이 비슷한 재학습률을 나타내면서 평균 평가점수가 큰 차이를 나타내는 하나의 이유는 동적 학습에서는 고정된 시퀀싱이 적용된 반복 학습보다 1회의 재학습이 더 추가되기 때문이며, 또한 반복 학습은 전체 학습을 1회 재학습하고 동적 학습은 학습 모듈별로 2회 재학습을 수행하게 되어 전체적인 학습 시간은 비슷하게 소요되면서 학습 효율은 증대되었기 때문이다. 반복학습과 동적 학습의 평균 학습 시간이 3분의

<표 1> 학습 시스템별 학습

|         | 일반 학습  | 반복 학습  | 동적 시퀀싱 |
|---------|--------|--------|--------|
| 평균 학습시간 | 37 분   | 55 분   | 58 분   |
| 평균 평가점수 | 49 점   | 71 점   | 87 점   |
| 분당 취득점수 | 1.32 점 | 1.29 점 | 1.5 점  |
| 재학습률    | -      | 65%    | 67%    |


극소한 차이만을 나타내는 이유는 전술한 바와 같이 고정된 시퀀싱이 적용된 반복 학습은 탈락한 학습 전체를 재학습하지만, 동적 시퀀싱이 적용된 동적 학습은 부족한 학습 모듈만을 재학습하기 때문이다. 본 실험 결과로 알 수 있는 것은 학습 시스템에서 학습자에게 필요한 학습 모듈을 선택적으로 결정하는 것이 학습 효율을 높이는데 중요한 역할을 한다는 것이다. 즉, 학습 전반에 대해 재학습을 수행하는 것보다 필요한 학습만을 학습 모듈별로 진행하는 것이 비슷한 학습 시간을 사용하면서 학습 성취도를 향상시킬 수 있다는 것을 본 실험 결과로 알 수 있었다.

4.2 가상의 학습 집단을 이용한 시뮬레이션

본 학습 시뮬레이션에서는 가상의 학습 집단을 이용하여 동적 시퀀싱에서 학습자들의 학습 능력에 맞게 기준점수가 어떻게 적용해 가는지 관찰하고, 고정된 시퀀싱과 동적인 시퀀싱 모델의 학습을 시퀀싱의 타당성 측면에서 비교한다. 학습 시뮬레이션은 평균을 기준점수에 적용한 실험과 표준 정규분포를 기준점수에 적용한 실험으로 나뉜다.

평균을 기준점수에 적용한 실험에 사용된 가상의 학습 집단은 50명의 가상 학습자들을 설정하고, 학습 집단의 평균이 60점이 되도록 가상의 평가점수를 랜덤하게 생성하였다. 본 실험에서는 평균 이하의 학습자들은 재학습을 받는 것이 타당하다고 가정한다. 시퀀싱을 위한 기준점수는 학습 설계자가 40점으로 설계한 경우와 80점으로 설계한 경우를 가정하였고,  $N_{max} = 10$ ,  $a = 0.2$ 를 적용하였다.

(그림 11)은 학습자의 평가점수와 동적 시퀀싱의 기준점수 변화를 학습자별로 나타낸 실험 결과이다. 시뮬레이션



(그림 11) 학습자 평가점수와 시퀀싱 기준점수의 변화



결과를 보면 동적 시퀀싱을 위한 기준점수가 학습 집단의 평가 결과에 따라 적절한 값으로 수렴해 가는 것을 볼 수 있다. 즉, 본 결과는 학습 설계자가 학습 시퀀싱을 정의할 때 너무 높거나 낮은 기준점수를 정의하더라도 학습 집단의 학습 평가 결과에 따라 기준점수가 적절한 수준으로 적응해 나갈 수 있음을 나타낸다.

<표 2>는 1번 가상 학습자부터 20번 가상 학습자까지의 학습 이수(통과) 여부에 대한 오류를 나타낸 표이다. 평균에 미달하는 학습자는 재학습을 필요로 한다고 가정할 때, 적절한 학습 이수(통과) 기준점수는 학습 집단의 평균인 60점이라고 할 수 있다. <표 2>에서는 기준점수가 40점일 때와 80점일 때 고정된 시퀀싱과 동적인 시퀀싱에 의해 기준점수가 조정되는 경우의 재학습 판단 여부를 비교하여 나타내었다. 시뮬레이션의 결과에 따라 각각의 시퀀싱이 학습 통과 여부를 잘못 판정한 경우들을 진한 색으로 나타내었다. 기준점수를 80점으로 정의한 경우 고정된 시퀀싱에서는 6명의 학습자들에 대하여 재학습 여부를 잘못 판단하게 되며, 동적 시퀀싱에서는 5명의 학습자들을 잘못 판단하게 된다. 기준점수를 40점으로 활용한 경우 고정된 시퀀싱에서는 10명의 학습자들에 대하여 재학습 여부를 잘못 판단하게 되며, 동적 시퀀싱에서는 4명의 학습자들을 잘못 판단하게 된다.

<표 3>은 전체 가상 학습자 집단에서 고정된 시퀀싱과 동적 시퀀싱이 적용되었을 경우 발생한 재학습 오류 결과이다. 적절한 학습 이수(통과) 기준점수를 학습 집단의 평균인 60점이라 가정할 때 가상의 학습 집단에서 재학습이 필요한 대상자는 총 25명이다. 기준점수가 40점일 경우 고정된 시퀀싱에서는 6명만이 재학습 대상으로 판단되어 재학습을 수행하여야 할 19명의 학습자가 학습 통과자로 결정되므로써 재학습 오류가 76%에 달하였다. 그러나 동적 시퀀싱에서는 23명이 재학습 대상으로 판단되었고 재학습을 수행하여야 할 학습자 중 2명만이 학습 통과자로 결정되어 재학습 오류가 8%로 매우 낮게 나타났다. 기준점수가 80점일 경우에도 고정된 시퀀싱에서는 전체 학습자의 84%에 해당하는 42명이 재학습을 받게 되는 경우가 발생하여 재학습 오류가 68%에 달하지만, 동적 시퀀싱에서는 재학습 오류가 4%로 매우 낮다. 이와 같은 결과는 교수자나 학습 저작자의 착오로 기준점수가 잘못 결정하면 학습 집단의 평가가 올바르게 수행되지 못한다는 것과, 이로 인하여 학습 능력 향상을 위한 반복 학습이 매우 비효율적으로 적용될 수 있음을 보여준다. 동적인 시퀀싱은 적절하지 못한 기준점수를 학습 집단에 적합한 수준으로 변화시키므로 이러한 비효율적인 재학습의 가능성을 낮출 수 있다.


표준정규분포를 기준점수에 적용한 실험에 사용된 가상의 학습 집단은 50명의 가상 학습자들을 설정하고 학습 집단의 평균이 60점이 되도록 가상의 평가점수를 랜덤하게 생성하였다. 본 실험에서는 상위 30%에 해당하는 학습자들만을 학습 통과자로 결정하는 것이 타당하다고 가정한다. 시퀀싱을 위한 기준점수는 학습 설계자가 40점으로 설계한 경우와 90점으로 설계한 경우 가정하였고,  $N_{max}$ 는 학습 집단에 포함

<표 2> 가상 학습 집단의 학습 평가 오류 비교

| 학습자      | 평가점수 | 적절한 학습 이수(통과) 여부 | 기준점수=80점 |        | 기준점수=40점 |        |
|----------|------|------------------|----------|--------|----------|--------|
|          |      |                  | 고정된 시퀀싱  | 동적 시퀀싱 | 고정된 시퀀싱  | 동적 시퀀싱 |
| 1번 학습자   | 48점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 통과       | 통과     |
| 2번 학습자   | 67점  | 통과               | 재학습      | 재학습    | 통과       | 통과     |
| 3번 학습자   | 59점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 통과       | 통과     |
| 4번 학습자   | 68점  | 통과               | 재학습      | 통과     | 통과       | 통과     |
| 5번 학습자   | 81점  | 통과               | 통과       | 통과     | 통과       | 통과     |
| 6번 학습자   | 42점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 7번 학습자   | 65점  | 통과               | 재학습      | 통과     | 통과       | 통과     |
| 8번 학습자   | 29점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 재학습      | 재학습    |
| 9번 학습자   | 43점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 10번 학습자  | 58점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 11번 학습자  | 51점  | 탈락(-재학습 대상)      | 재학습      | 통과     | 통과       | 재학습    |
| 12번 학습자  | 70점  | 통과               | 재학습      | 재학습    | 통과       | 통과     |
| 13번 학습자  | 45점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 14번 학습자  | 58점  | 탈락(-재학습 대상)      | 재학습      | 통과     | 통과       | 통과     |
| 15번 학습자  | 37점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 재학습      | 재학습    |
| 16번 학습자  | 67점  | 통과               | 재학습      | 통과     | 통과       | 통과     |
| 17번 학습자  | 59점  | 탈락(-재학습 대상)      | 재학습      | 통과     | 통과       | 통과     |
| 18번 학습자  | 84점  | 통과               | 통과       | 통과     | 통과       | 통과     |
| 19번 학습자  | 71점  | 통과               | 재학습      | 통과     | 통과       | 통과     |
| 20번 학습자  | 48점  | 탈락(-재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 학습 평가 오류 |      |                  | 6명       | 5명     | 10명      | 4명     |

<표 3> 가상 학습 집단의 재학습 오류율

|        | 평가점수  | 기준점수=40점  |         | 기준점수=80점  |         |
|--------|-------|-----------|---------|-----------|---------|
|        |       | 고정된 시퀀싱   | 동적 시퀀싱  | 고정된 시퀀싱   | 동적 시퀀싱  |
| 평균     | 60점   | 40점       | 58점     | 80점       | 61점     |
| 표준편차   | 17.11 | 0         | 4.47    | 0         | 4.01    |
| 분산     | 293   | 0         | 19.96   | 0         | 16.10   |
| 학습통과   | 25명   | 44명       | 27명     | 8명        | 26명     |
| 재학습    | 25명   | 6명        | 23명     | 42명       | 24명     |
| 재학습 오류 | -     | 76% (19명) | 8% (2명) | 68% (17명) | 4% (1명) |



(그림 12) 상위 30%에 대한 표준정규분포 기준점수의 변화

된 학습자들의 총수로 하였다.

(그림 12)는 상위 30% 학습자들을 결정하기 위한 고정 시퀀싱과 동적 시퀀싱의 변화를 나타낸 실험 결과이다. 실험 결과에서 학습자의 평가점수와 동적 시퀀싱에서 표준정규분포를 적용한 기준점수 변화를 학습자별로 나타내었다.

시뮬레이션 결과를 보면 동적 시퀀싱을 위한 기준점수가 학습집단의 평가 결과에 따라 적절한 값으로 수렴해 가는 것을 볼 수 있다. 즉, 학습 설계자가 학습 시퀀싱을 정의할 때 너무 높거나 낮은 기준점수를 정의하더라도 학습 집단의 학습 평가 결과에 따라 표준정규분포를 적용한 기준점수가 적절한 수준으로 적용해 나갈 수 있음을 나타내는 것이다.

<표 4>는 학습 집단의 상위 30%를 학습 이수(통과) 기준으로 활용할 경우에 대한 실험 결과이며, 1번부터 20번 가상 학습자까지를 대상으로 학습 이수(통과) 오류를 나타낸 표이다. 초기 기준점수로 40점과 90점이 활용되었으며, 이와 같이 극단적인 기준점수를 초기 기준점수로 활용한 이유는 고정 시퀀싱과 동적 시퀀싱이 극단적인 기준점수가 입력되어도 올바르게 학습 집단에 적용하는지를 평가하기 위해서이다. 시뮬레이션의 결과에 따라 각각의 시퀀싱이 상위 30% 포함 여부를 잘못 판단한 경우들은 진한 색으로 나타내었다. 기준점수를 40으로 정의한 경우 고정된 시퀀싱에서는 10명의 학습자들에 대하여 학습 평가 여부를 잘못 판단하게 되며, 동적 시퀀싱에서는 1명의 학습자에 대해서만 학습 평가 여부를 잘못 판단하게 된다. 기준점수를 90점으로 정의한 경우 고정된 시퀀싱에서는 4명의 학습자들에 대해 학습 평가 여부를 잘못 판단하게 되며, 동적 시퀀싱에서는 1명의 학습자에 대해서만 학습 평가 여부를 잘못 판단하게 된다. 고정된 시퀀싱에서 기준점수에 따라 학습 평가 오류가 큰 차이를 나타내는 이유는 전체 학습 집단의 학습 평가를 고정된 시퀀싱에서는 전적으로 학습 설계자에게만 의존하기 때문이며, 전체 학습 집단의 특성을 잘 나타내지 못하는 기준점수(기준점수=40점)를 적용하였을 경우에는 실험 결과에서 나타난 바와 같이 큰 평가 오류가 발생한다.

<표 5>는 상위 30%에 해당하는 가상 학습 집단의 학습 평가 오류에 대한 실험 결과이다. 상위 30%에 해당하는 학습자들만을 적절한 학습 이수자로 결정한다면 상위 15등까

<표 4> 가상 학습 집단의 상위 30% 포함 오류 비교

| 학습자      | 평가 점수 | 적절한 학습 이수(통과) 여부 | 기준점수=90점 |        | 기준점수=40점 |        |
|----------|-------|------------------|----------|--------|----------|--------|
|          |       |                  | 고정된 시퀀싱  | 동적 시퀀싱 | 고정된 시퀀싱  | 동적 시퀀싱 |
| 1번 학습자   | 55점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 통과     |
| 2번 학습자   | 76점   | 통과               | 재학습      | 재학습    | 통과       | 통과     |
| 3번 학습자   | 72점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 4번 학습자   | 87점   | 통과               | 재학습      | 통과     | 통과       | 통과     |
| 5번 학습자   | 91점   | 통과               | 통과       | 통과     | 통과       | 통과     |
| 6번 학습자   | 65점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 7번 학습자   | 32점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 재학습      | 재학습    |
| 8번 학습자   | 82점   | 통과               | 재학습      | 통과     | 통과       | 통과     |
| 9번 학습자   | 63점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 10번 학습자  | 60점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 11번 학습자  | 19점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 재학습      | 재학습    |
| 12번 학습자  | 63점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 13번 학습자  | 94점   | 통과               | 통과       | 통과     | 통과       | 통과     |
| 14번 학습자  | 58점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 15번 학습자  | 33점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 재학습      | 재학습    |
| 16번 학습자  | 74점   | 통과               | 재학습      | 통과     | 통과       | 통과     |
| 17번 학습자  | 49점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 18번 학습자  | 55점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 19번 학습자  | 27점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 재학습      | 재학습    |
| 20번 학습자  | 41점   | 탈락(=재학습 대상)      | 재학습      | 재학습    | 통과       | 재학습    |
| 학습 평가 오류 |       |                  | 4명       | 1명     | 10명      | 1명     |


<표 5> 상위 30%에 해당하는 가상 학습 집단의 학습 평가 오류율

|       | 평가점수   | 기준점수=90점 |         | 기준점수=40점  |         |
|-------|--------|----------|---------|-----------|---------|
|       |        | 고정된 시퀀싱  | 동적 시퀀싱  | 고정된 시퀀싱   | 동적 시퀀싱  |
| 평균    | 60점    | 90.00점   | 74.40점  | 40.00점    | 72.75점  |
| 표준편차  | 22.97  | 0        | 6.21    | 0         | 7.84    |
| 분산    | 527.47 | 0        | 38.60   | 0         | 61.47   |
| 학습통과  | 15명    | 6명       | 27명     | 41명       | 17명     |
| 재학습   | 35명    | 44명      | 23명     | 9명        | 33명     |
| 평가 오류 | -      | 18% (9명) | 4% (2명) | 52% (26명) | 4% (2명) |

지만 학습 이수자로 결정된다. 기준점수가 40점일 경우 고정된 시퀀싱에서는 26명이 평가 오류로 나타났으나, 동적 시퀀싱에서는 2명만이 평가 오류로 나타났다. 기준점수가 90점일 경우 고정된 시퀀싱에서는 9명이 평가 오류로 나타났지만, 동적 시퀀싱에서는 2명만이 평가 오류로 나타났다. 이와 같은 결과는 학습 평가자나 학습 저작자가 학습 집단을 올바르게 파악하지 못하거나 잘못된 기준점수를 활용할 경우 고정된 시퀀싱에서는 평가 오류가 크게 발생할 수 있다는 것을 나타낸다. 그러나 동적 시퀀싱은 학습 집단의 특성에 맞게 기준점수를 자동으로 변화시킴으로써 학습 집단에 적합한 평가를 가능하게 하는 장점이 있다.

(그림 13)은 학습 집단에서 하위 30% 학습자들만을 추출하기 위한 고정 시퀀싱과 동적 시퀀싱의 변화를 나타낸 실험 결과이다. 실험 결과에 학습자의 평가점수와 동적 시퀀싱에서 표준정규분포를 적용한 기준점수 변화를 학습자별로 나타내었다. 시뮬레이션 결과를 보면 동적 시퀀싱을 위한 기준점수가 학습 집단의 평가 결과에 따라 적절한 값으로 수렴해 가는 것을 볼 수 있다.

<표 6>은 학습 집단에서 하위 30%를 재학습 기준으로 활용할 경우에 대한 실험 결과이며, 1번부터 20번 가상 학습자까지를 대상으로 학습 평가 오류를 나타낸 표이다. 초기 기준점수로 10점과 80점이 활용되었으며, 시뮬레이션의 결과에 따라 각각의 시퀀싱이 하위 30% 포함 여부를 잘못 판단한 경우들은 진한 색으로 나타내었다. 기준점수를 10으로 정의한 경우 고정된 시퀀싱에서는 5명의 학습자들에 대해 학습 평가를 잘못 판단하게 되며, 동적 시퀀싱에서는 1명의



(그림 13) 하위 30%에 대한 표준정규분포 기준점수의 변화

〈표 6〉 가상 학습 집단의 하위 30% 평가 오류 비교

| 학습자      | 평가 점수 | 적절한 학습 이수(통과) 여부 | 기준점수=10점 |        | 기준점수=80점 |        |
|----------|-------|------------------|----------|--------|----------|--------|
|          |       |                  | 고정된 시퀀싱  | 동적 시퀀싱 | 고정된 시퀀싱  | 동적 시퀀싱 |
| 1번 학습자   | 55점   | 통과               | 통과       | 통과     | 재학습      | 재학습    |
| 2번 학습자   | 76점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 3번 학습자   | 72점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 4번 학습자   | 87점   | 통과               | 통과       | 통과     | 통과       | 통과     |
| 5번 학습자   | 91점   | 통과               | 통과       | 통과     | 통과       | 통과     |
| 6번 학습자   | 65점   | 통과               | 통과       | 재학습    | 재학습      | 재학습    |
| 7번 학습자   | 32점   | 탈락(=재학습 대상)      | 통과       | 재학습    | 재학습      | 재학습    |
| 8번 학습자   | 82점   | 통과               | 통과       | 통과     | 통과       | 통과     |
| 9번 학습자   | 63점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 10번 학습자  | 60점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 11번 학습자  | 19점   | 탈락(=재학습 대상)      | 통과       | 재학습    | 재학습      | 재학습    |
| 12번 학습자  | 63점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 13번 학습자  | 94점   | 통과               | 통과       | 통과     | 통과       | 통과     |
| 14번 학습자  | 58점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 15번 학습자  | 33점   | 탈락(=재학습 대상)      | 통과       | 재학습    | 재학습      | 재학습    |
| 16번 학습자  | 74점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 17번 학습자  | 49점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 18번 학습자  | 55점   | 통과               | 통과       | 통과     | 재학습      | 통과     |
| 19번 학습자  | 27점   | 탈락(=재학습 대상)      | 통과       | 재학습    | 재학습      | 재학습    |
| 20번 학습자  | 41점   | 탈락(=재학습 대상)      | 통과       | 재학습    | 재학습      | 재학습    |
| 학습 평가 오류 |       |                  | 5명       | 1명     | 11명      | 2명     |

〈표 7〉 하위 30%에 해당하는 가상 학습 집단의 학습 평가 오류율

|       | 평가점수   | 기준점수=10점  |         | 기준점수=80점  |         |
|-------|--------|-----------|---------|-----------|---------|
|       |        | 고정된 시퀀싱   | 동적 시퀀싱  | 고정된 시퀀싱   | 동적 시퀀싱  |
| 평균    | 60점    | 10.00점    | 48.87점  | 80.00점    | 51.12점  |
| 표준편차  | 22.97  | 0         | 6.21    | 0         | 7.84    |
| 분산    | 527.47 | 0         | 38.60   | 0         | 61.47   |
| 학습통과  | 15명    | 1명        | 15명     | 39명       | 16명     |
| 재학습   | 35명    | 49명       | 35명     | 11명       | 34명     |
| 평가 오류 | -      | 26% (13명) | 6% (3명) | 50% (25명) | 8% (4명) |

학습자에 대해서만 학습 평가를 잘못 판단하게 된다. 기준점수를 80점으로 정의한 경우 고정된 시퀀싱에서는 11명의 학습자들에 대해 학습 평가를 잘못 판단하게 되며, 동적 시퀀싱에서는 1명의 학습자에 대해서만 학습 평가를 잘못 판단하게 된다.

〈표 7〉은 하위 30%에 해당하는 가상 학습 집단의 학습 평가 오류에 대한 실험 결과이다. 하위 30%에 해당하는 학습자들만을 적절한 재학습자로 결정한다면 하위 15등까지만 학습 미이수자로 결정된다. 기준점수가 10점일 경우 고정된 시퀀싱에서는 13명이 평가 오류로 나타났으나, 동적 시퀀싱에서는 3명만이 평가 오류로 나타났다. 기준점수가 80점일 경우 고정된 시퀀싱에서는 25명이 평가 오류로 나타났지만, 동적 시퀀싱에서는 4명만이 평가 오류로 나타났다.

### 5. 결 론

온라인 학습 시스템의 가장 큰 문제점은 학습 콘텐츠 제작과 학습 시스템 유지에 대한 관리비용이 높다는 것에 있다. 온라인 학습 시스템의 유지 비용을 축소시키기 위해서는 온라인 학습 시스템에 관련된 많은 인원의 관리자나 교수자가 접근하는 것을 최소화하여야 하며, 온라인 학습 시스템을 자동화하여 온라인 학습 시스템의 관리비용을 최소

화시켜야 한다. 이와 같은 문제점을 해결하고 온라인 학습 시스템을 활성화시키기 위해서는 학습 집단의 분석을 통해 학습 콘텐츠의 재사용성을 증가시키고, 다양한 평가 방법을 통해 학습자의 학습 능률을 향상시켜야 한다. 이러한 문제점을 해결하기 위한 하나의 방법은 본 논문에서 제안한 시퀀싱을 이용한 학습 시스템의 자동화이다.

또한, 기존의 e-learning에서 정해진 교육 절차에 따라 학습을 수행하고 종료하는 방식은 학습수준에 따라 적절한 교육을 제공하지 못한다. 이와 같은 문제점을 해결하기 위해 SCORM에서는 학습에 대한 시퀀싱을 정의함으로써 학습 과정을 달리할 수 있는 방안을 제시한다. 그러나 현재 활용되는 시퀀싱은 교수자나 학습 저작자가 사전에 시퀀싱을 정의하여 시퀀싱이 고정됨으로, 학습 설계자가 학습 집단에 적절하지 못한 시퀀싱을 정의하였을 때에 잘못된 시퀀싱이 학습자들에게 일률적으로 적용되는 문제점이 발생한다. 이러한 문제를 해결하기 위한 방법은 본 논문에서 제안한 동적 시퀀싱의 적용이다.

본 논문에서는 이와 같은 문제점들을 해결하기 위해 동적 시퀀싱을 적용한 자동화된 학습 시스템을 제안한다. 동적 시퀀싱은 학습자들의 평가점수를 시퀀싱의 기준점수에 자동적으로 반영하여 기준점수를 동적으로 변화시키는 것이다. 평균과 표준정규분포를 활용한 기준점수를 동적으로 변화시킴으로써 고정된 시퀀싱이 모든 학습 집단에 일률적으로 적용되지 않고, 학습자들의 수준에 따라 교육 평가를 효과적으로 할 수 있도록 시퀀싱이 동적으로 변화되어 간다. 본 논문에서 제안한 동적 시퀀싱이 고정 시퀀싱보다 효율적으로 자동 학습 시스템에 적용될 수 있다는 것을 실제 학습 집단 실험과 가상 학습 집단 시뮬레이션을 통해 확인하였다.

향후, 학습자들의 평가점수뿐만 아니라 학습자의 과거 학습 내용, 학습 경로, 학습 시간, 접속 위치등과 같은 다양한 학습에 대한 상황 속성을 이용하여 학습 시퀀싱을 최적으로 변화시키는 방법에 대한 연구가 필요하다.

### 참 고 문 헌

[1] Bohl, J. Scheuhase, R. Sengler, and U. Winand, "The Sharable Content Object Reference Model (SCORM) A Critical Review," *Proceedings of the IEEE International Conference on Computers in Education*, 2002.

[2] P. Brusilovsky and J. Vassileva, "Course sequencing techniques for large-scale web-based education," *International Journal of Continuing Engineering Education and Lifelong Learning*, Vol.13, No.1-2, pp.75-94. 2003.

[3] F. C. Chang, W. C. Chang, H. C. Yang, T. K. Shih, and H. C. Keh "Courseware Development Using Influence Diagram with SCORM Compatibility," *Proceedings of the 2004 IEEE International Conference on Multimedia and Expo*, 2004.

[4] W. C. Chang, H. W. Lin, T. K. Shih, and H. C. Yang,

“SCORM Learning Sequence Modeling with Petri Nets in Cooperative Learning,” *Learning Technology Newsletter of the IEEE*, Vol.7, Issue.1, 2005.

[5] C. P. Chu, C. P. Chang, C. W. Yeh, and Y. F. Yeh, “A Web-Service Oriented Framework for building SCORM Compatible Learning Management Systems,” *Proceedings of the ITCC 2004*, 2004.

[6] M. Frantzi, N. Moutoutzis, and S. Christodoulakis, “A Methodology for the Integration of SCORM with TV-Anytime for Achieving Interoperable Digital TV and e-Learning Applications,” *Proceedings of the IEEE International Conference on Advanced Learning Technologies*, 2004.

[7] J. Hasebrook, “Learning in the learning organization,” *Journal of Universal Computer Science*, Vol.7, No.6, pp.472-487, 2001.

[8] D. Helic, H. Maurer, and N. Scerbakov, “Combining Individual Tutoring with Automatic Course Sequencing in WBT Systems,” *Proceedings of the 13th International World Wide Web Conference*, 2004.

[9] D. Helic, H. Maurer, J. Lennon, and N. Scerbakov, “Aspects of a modern WBT system,” *Proceedings of the SSGRR2001*, 2001.

[10] X. Hu and A. Olney, “ITS and SCORM,” *Learning Technology Newsletter of the IEEE*, Vol.7, Issue.1, 2005.

[11] A. H. Jacqueline and M. Preetam, “Sequencing and Navigation in Simulation-based Training,” *Learning Technology Newsletter of the IEEE*, Vol.7, Issue.1, 2005.

[12] S. T. Li, C. H. Lin, Y. C. Chang, and J. Y. Yang, “On the Distributed Management of SCORM-compliant Course Contents,” *Proceedings of the EEE 2004*, 2004.

[13] H. W. Lin, T. K. Shih, W. C. Chang, C.H. Yang, and C.C. Wang, “A Petri nets-based approach to modeling SCORM sequence,” *Proceedings of the IEEE International Conference on Multimedia and Expo*, 2004.

[14] Qu and W. Nejdl, “Searching SCORM Metadata in a RDF-based E-Learning P2P Network Using XQuery and Query by Example,” *Proceedings of the IEEE International Conference on Advanced Learning Technologies*, 2003.

[15] H. Watanabe, S. Koga, and K. Kato, “Development of Learning Management System and SCO Presentation Program Based on SCORM,” *Proceedings of the IEEE International Conference on Advanced Learning Technologies*, 2004.

[16] J. T. Yang, C. H. Chiu, C. Y. Tsai, and T. H. Wu “Visualized Online Simple Sequencing Authoring Tool for SCORM-compliant Content Package,” *Proceedings of the*


*IEEE International Conference on Advanced Learning Technologies*, 2004.

[17] J. T. Yang and C. Y. Tsai, “An Implementation of SCORM-compliant Learning Content Management System – Content Repository Management System,” *Proceedings of the IEEE International Conference on Advanced Learning Technologies*, 2003.

[18] Advanced Distributed Learning, <http://www.adlnet.org>


[19] CLEO, <http://www.lsal.cmu.edu/lsal/expertise/projects/cleo/index.html>

[20] LSAL, <http://www.lsal.cmu.edu>



**이 종 군**

e-mail : jklee@dongguk.edu  
 2004년 동국대학교 컴퓨터공학과(공학석사)  
 관심분야: e-learning, 기계학습, 지능형 에이전트



**김 형 일**

e-mail : hikim@dongguk.edu  
 1996년 목원대학교 수학과(이학사)  
 1996년~1998년 (주)경기은행  
 2001년 동국대학교 컴퓨터공학과(공학석사)  
 2004년 동국대학교 컴퓨터공학과(공학박사)  
 2005년~2006년 동국대학교 컴퓨터공학과 IT분야 교수요원(정보통신부)  
 관심분야: 지능형 에이전트, 기계학습, 정보검색, e-learning, 지능형 게임



**김 준 태**

e-mail : jkim@dongguk.edu  
 1986년 서울대학교 제어계측공학과(공학사)  
 1990년 미국 Univ. of Southern California, Electrical Engineering-Systems (M.S.).  
 1993년 미국 Univ. of Southern California, Computer Engineering(Ph.D.)  
 1994년~1995년 미국 Southern Methodist University, Computer Science and Engineering(Postdoc).  
 1995년~현재 동국대학교 컴퓨터공학과 교수  
 관심분야: 기계학습, 데이터마이닝, 정보검색, 지능형 에이전트, e-learning