학습 상태에 기반한 맞춤형 난이도 측정을 위한 척도 설계

정우성 서울교육대학교 교육전문대학원 교수

A Design for the Personalized Difficulty Level Metric based on Learning State

Woosung Jung

Professor, Graduate School of Education, Seoul National University of Education

요 약 난이도는 학습자가 컨텐츠를 선택하는 중요한 기준 중 하나이다. 하지만, 대부분의 난이도 기준은 컨텐츠 제공자가 획일적으로 결정한다. 이러한 방식으로는 학습자의 다양한 수준과 환경을 고려한 맞춤형 교육을 지원할 수 없다. 본 연구는 이 문제를 해결하기 위하여 학습자와 컨텐츠의 지식을 정형화하고 일반화한 후, 이를 실험하기 위한 객체모델과 맞춤형 난이도 척도를 설계하였다. 또한, 이를 검증하기 위한 목적으로 구현한 도구를 이용하여 100개의 음악교육 컨텐츠와 20명의 학습자를 기반으로 시뮬레이션을 진행했다. 실험 결과는 제안한 방법이 학습 상태와 컨텐츠에서정의한 지식의 유사도를 이용하여 맞춤형 난이도를 계산할 수 있음을 보여 주었다. 제안한 접근법은 학습 상태와 컨텐츠에 쉽게 접근할 수 있는 온라인 학습 시스템에 효과적으로 적용할 수 있다.

주제어: 컨텐츠, 난이도, 척도, 맞춤형 교육, 학습 상태

Abstract The 'level of difficulty' is one of the major factors for learners when selecting learning contents. However, the criteria for the difficulty level is mostly defined by the contents providers. This approach does not support the personalized education which should consider the abilities and environments of various learners. In this research, the knowledge of the learners and contents were formalized and generalized to resolve the issue, and object models, including a metric for personalized difficulty level, were designed in order to be applied for experiments. And then, based on 100 contents for music education and 20 learners, we performed simulations with an implemented tool to validate our approach. The experimental results showed that our method can calculate the personalized difficulty levels considering the similarities between the knowledges from the learning state and the contents. Our approach can be effectively applied to the on-line learning management system which contains easy access to the learning state and contents data.

Key Words: Contents, Difficulty Level, Metric, Personalized Education, Learning State

1. 서론

일반적으로 학습 컨텐츠의 난이도는 컨텐츠 제공자의

기준에 따라 획일적으로 정해진다. 하지만, 학습자의 관심도와 경험에 따라 실제 습득한 지식의 종류와 수준이 사람마다 다를 수 있다. 그러므로, 보다 정확한 난이도를

Received January 20, 2020 Accepted March 20, 2020 Revised February 28, 2020 Published March 28, 2020

^{*}This work was supported by the 2019 Research Fund of Seoul National University of Education.

^{*}Corresponding Author: Woosung Jung(wsjung@snue.ac.kr)

파악하기 위해서는 학습자의 학습 상태에 따라 상대적으로 난이도를 계산해야 한다. 이러한 개별화에 따른 상대적 난이도는 맞춤형 교육 실현을 위한 기준으로 사용할수 있다. 본 연구에서 제안하는 컨텐츠 난이도 척도는 학습자의 학습 상태를 기준으로 원하는 수준의 컨텐츠를 검색할 때 사용할수 있기 때문에 맞춤형 교육을 위한 학습 컨텐츠를 추천하거나, 효과적인 학습 경로 설계에 활용할수 있다.

학습 컨텐츠 난이도를 정의하려면 학습자의 학습 상태와 대상 컨텐츠의 내용 및 수준을 비교해야 한다. 본 연구에서는 학습 대상이 되는 학습 요소들의 집합과 이들의 관계를 정형적으로 정의한 학습 그래프를 기준으로 새로운 지식의 복잡도와 유사도를 이용한 상대적 난이도 척도를 정의하였다. 학습 요소의 수준은 사전 데이터가 필요하기 때문에 본 연구에서는 모든 학습 및 컨텐츠 생성 과정을 시뮬레이션을 거쳐 생성하였다. 그리고, 학습자의 학습 상태에 포함되지 않은 학습 요소들에 대한 지식은 고려하지 않았다. 이러한 가정은 난이도 계산에서 학습자가 해당 컨텐츠에 대한 지식을 가졌음에도 불구하고 난이도에 반영 못하는 상황을 만들 수 있지만, 온라인 활동 등을 통해 지속적으로 학습 상태를 업데이트할 수 있으므로 본 연구의 실험 결과에 일반성을 잃지 않는다.

본 논문의 이후 구성은 다음과 같다. 2장에서는 맞춤형 교육과 난이도 척도 정의에 사용하는 지식 정보 모델링 등을 포함한 관련 연구들을 살펴보고, 3장에서는 본연구가 해결하고자 하는 문제 도메인에 대한 가정과 해결 방안인 맞춤형 난이도 척도를 정형적으로 정의하였으며, 검증 실험을 위해 구현한 소프트웨어의 주요 객체 설계 및 알고리즘에 대한 설명을 포함하였다. 4장에서는 본연구에서 제안하는 맞춤형 난이도 척도의 검증을 위해음악 교육 컨텐츠를 대상으로 실험을 진행하고 결과를정리하였으며, 5장에서 결론을 맺는다.

2. 관련 연구

학습자가 컨텐츠에 대한 평가 활동에 참여하여 얻은 데이터를 기반으로 컨텐츠의 난이도를 분석하는 연구들이 있었다[1,2]. 사용자의 수준을 파악하는 테스트 제작을 위해 IRT(Item Reseponse Theory)를 이용하기도 했다[3]. 해당 연구는 사전에 확보한 데이터베이스에서 사용자 정보와 관련 주제를 추출하여 테스트를 반복적으로 수행하면서 적응시키는 방법으로 인공신경망을 활용

하였다. 하지만, 평가 결과를 이용한 연구는 컨텐츠에 대한 학습자의 문항반응에 기반한 통계적 방법으로 난이도의 정확도를 높일 수 있으나 테스트 참여라는 학습자의 적극적 활동에 의존적이므로 이에 대한 부담과 비용이 발생한다.

평가 문항을 통하여 간접적으로 학습자의 지식 상태 구조와 위계를 파악하려는 연구도 있었다[4]. 지식 상태 분석을 통해 학습 전 학습자 개별의 출발점 상태 확인과 진단평가로 활용하고, 학습 후의 지식 상태도는 형성평가와 향후 교수학습 효과를 확인하기 위한 용도로 활용한연구[5,6]는 학습 상태 모델링의 유용성을 잘 보여준다.특히, 학습 상태는 난이도 계산을 포함하여 맞춤형 교육을 위해 학습자의 지식 상태 추적에 필수적이므로 맞춤형 교육[7]에서 효과적으로 활용할 수 있다. 본 연구는 이러한 기존 연구와 달리 학습자의 평가 참여보다는 지속적인 컨텐츠 접촉으로 획득되는 학습 상태 정보를 이용한다.

초중고 교과서의 텍스트 난이도를 단락 수, 단락 내 문장 수, 문장 수, 문장 내 어절 수, 문장 내 글자 수, 어절수, 이형 어절수, 새 어절 출현비율, 어절 내 글자수 등9가지 요인을 이용하여 공식을 통해 계산한 연구가 있었다[8]. 하지만, 이 방법은 학습자의 학습 상태를 고려하지않고, 컨텐츠 제공자의 입장에서 난이도를 계산하기 위한기준을 연구하였다는 점에서 본 연구와 차이가 있다.

맞춤형 교육을 위해 학습 경로를 최적화하기 위한 연구의 경우는 사전 테스트를 통해 사용자의 수준을 파악하고 이를 바탕으로 개인의 난이도에 맞게 지속적으로학습해 나갈 수 있도록 커리큘럼을 만드는 접근법[9], 일반적인 알고리즘으로는 해결이 어려운 학습 경로 탐색최적화 문제를 유전알고리즘을 이용하여 해결한 연구[10] 등이 있었다. 지능형학습 시스템과 관련한 연구도 있었는데, 개인화학습코스를 추천한 모델에 대한 연구[11]는 단어별 가중치를 계산하여 코사인 유사도를활용하였으나 난이도에 대한 정량적인 척도는 고려하지 않았다. 학습자 프로파일을 이용하여 긍정 또는 부정의 피드백을 분류하기도 하였다[12]. 본 논문의 난이도 척도를이용하면 낮은 비용의 탐욕(Greedy) 알고리즘을이용하여 합리적 수준의학습 경로를 생성할때 활용가능한 장점이 있다.

맞춤형 교육 시스템 설계와 학습 분석 이론을 기초로 PERLA(Personalization and Learning Analytics) 프 레임워크를 제안한 연구[13]는 7단계 맞춤형 학습을 기반으로 수행과 평가를 반복한다. 강화학습을 이용한 1대

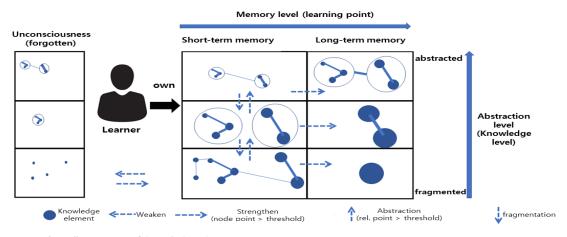


Fig. 1. Overall concepts of knowledge domain

1 튜터링을 통해 학습자의 수준에 맞추는 로봇을 제안한 연구[14,15]도 있었는데, 로봇과 학습자가 지속적인 상호 작용을 진행함을 가정하고 있다. 온라인 학습 개별화 전략 분석을 위한 일반화된 척도를 제안한 연구[16]는 난이도 척도와는 별개로 학습자의 특성을 반영하여 최선의이러닝 환경을 구축하기 위한 목적으로 진행되었다. 학생맞춤형 다차원 분석을 위한 기초 설계와 구현을 진행한연구[17]도 있었는데, 학생의 성적과 장래희망 등의 정성적인 데이터와 평가 결과를 기반으로 난이도를 확인하기위한 간단한 테이블로 구성하여 기초 통계 중심의 분석을 지원하였으나 컨텐츠 수준에서의 분석은 어려웠다. 학습자의 맞춤형 교육을 통해 학습에 대한 흥미를 높이기위한 연구[18]도 있었는데, 본 연구에서 제안하는 학습자의 지식 상태는 학습자 관심분야에 대한 힌트를 제공할수 있기 때문에 관련연구에 기여할 수 있다.

3. 도메인 정의 및 지식 구조 모델링

3.1 도메인 정의

Fig. 1은 본 연구에서 가정하고 있는 지식 도메인에 대한 전반적인 개념을 보여준다. 학습자(learner)는 지식 요소(element)들과 이들의 관계(relation)로 구성된 그 래프 형태의 지식(knowledge)을 소유한다. 지식 요소와 관계는 각각 학습 점수를 가지고 있으며, 학습이 충분히 이루어지고 강화될 경우 장기 기억에 지식이 저장되며, 반대의 경우는 망각 상태로 넘어가게 된다. 그러므로, 학습 점수는 대상 컨텐츠에 대한 학습자의 학습 수준을 반 영한다. 이에 비해, 각 요소들이 서로 강한 연결을 가지는

일종의 클러스터를 형성하게 되면 이 클러스터가 하나의 지식 요소처럼 재귀적으로 처리될 수 있는데 이렇게 지식의 연결이 강화되며 상세 요소를 클러스터로 묶는 것을 추상화(abstraction) 과정으로, 반대의 경우를 단편화(fragmentation) 과정으로 구분하여 정의한다.

3.1.1 학습자와 지식요소

학습자 \mathbf{m} 명이 \mathbf{n} 개의 지식요소를 학습하는 경우를 가정하면 전체 학습자 집합 $L = \{l_1, l_2, ..., l_m\}$ 로, 전체 지식 $K = \{k_1, k_2, ..., k_n\}$ 로 표현할 수 있다. 가령, 영단어를 공부를 위해 학습해야할 전체 단어를 K 라고 하면 각각의 단어가 $k_1 ... k_n$ 에 해당한다. 영희, 철수가 'apple', 'banana', 'kiwi', 'orange' 4개 단어를 공부하는 경우라면 $L = \{$ 영희, 철수 $\}$.

 $K = \{'apple', 'banana', 'kiwi', 'orange'\}$ 가 된다.

3.1.2 지식요소 점수

Fig. 2는 지식 요소 점수 행렬 P를 정의하고 있다. 학습자 l_i 가 지식요소 k_j 에 대해 학습한 수준을 지식요소 점수 $p_{i,j}$ 라고 한다. 공부한 횟수 또는 관련 단어 시험에서 정답을 맞춘 횟수, 또는 이들의 조합으로 만든 다양한 척도가 가능하다. 시간에 따른 강화 또는 망각의 정도를 고려한 함수를 추가할 수도 있다. 즉, 재학습이 이루어지지 않은 상태에서는 일정 비율로 점수를 감소시킬 수 있다. 학습자는 지식요소 점수가 높을수록 해당 지식요소에더 익숙하다고 판단한다. 일정 수준 이상 반복된다면 해당 요소는 장기 기억으로 이동된다. 최종적으로는 표준화된 점수를 이용하여 상대적으로 학습이 덜 된 내용을 검

색하거나 재학습이 필요한 지식요소들을 찾는 것도 가능하다. $p_{i,j}$ 를 i행 j열의 요소로 가지는 행렬 P를 정의한다면, 학습자 l_i 의 지식 요소별 점수 $P(l_i)$ 와 지식 k_j 의 학습자별 점수 $P(k_j)$ 는 각각 열벡터와 행벡터로 표현이 가능하다.

$$\begin{split} P &= \begin{bmatrix} p_{1,1} & \dots & p_{1,n} \\ \dots & p_{i,j} & \dots \\ p_{m,1} & \dots & p_{m,n} \end{bmatrix} \\ P(l_i) &= P_{L(i)} = \begin{bmatrix} p_{i,1}, \dots, p_{i,n} \end{bmatrix} \\ P(k_j) &= P_{K(j)} = \begin{bmatrix} p_{1,j} \\ \dots \\ p_{m,j} \end{bmatrix} \\ \cdot p_{i,j} &: \text{Learner } l_i \text{'s learning(node) point for the knowledge} \\ &= \text{element } k_j \end{split}$$

Fig. 2. Point for knowledge elements

3.1.3 지식요소 그래프

Fig. 3은 지식 요소 관계 집합 E를 정의하고 있다. E의 요소는 학습자를 첫 번째 요소로 가지는 리스트(list) 구조를 가지고 있다. $E(l_i)$ 는 학습자 l_i 가 지식 집합 K에서 학습을 통해 경험한 지식요소들간의 관계 또는 연결 정보로, 지식요소들을 노드(node)로 가지는 방향성 그래프(directed graph) 구축에 필요하다. 그래프의 엣지(edge)는 방향(direction) 외 지식요소 간의 타입(type) 정보와 점수(point)를 가진다. 즉, 연속되거나 인접해있는 정도를 이용해서 의미와 가중치를 각각 타입과점수로 부여할 수 있다. 가령 "yellow banana" 라는 표현이 학습(또는 노출)되었다면 "yellow"와 "banana" 노드 사이에 엣지(edge)가 생성되며 연결점수 만큼 가중치를 가지게 된다. 이 연결점수는 학습 요소 점수와 마찬가지로 학습 빈도, 학습자 특성 등에 따라 차이가 있는 동적인 값이다.

$$\begin{split} E(l_i) = & \left\{ [l_i, [g, \, k_x, \, k_y, t, p]] \, | \, g {\in} N, k_x, k_y {\in} K, t {\in} T, p {\in} \mathcal{R} \right\} \\ T = & \left\{ Sequence, \; Composition, \; Association \right\} \end{split}$$

- $oldsymbol{\cdot} g$: a grouping number for each clusters
- $oldsymbol{\cdot} S$: a sequence number for the elements of each clusters
- $\cdot k_x k_y$: connected knowledge elements
- \cdot t: connection type
- $\cdot p$: learning(relation) point for each connections

Fig. 3. Point for knowledge relation

 $P(l_i)$ 와 $E(l_i)$ 를 이용하면, 지식요소 및 해당 지식요 소 점수를 노드로 가지고, 노드 간 관계 점수를 가중치로 가지는 학습자 l_i 의 학습 상태 그래프를 표현할 수 있다.

 $E(l_i)$ 의 연결 점수가 임계치(threshold)를 넘어서 강한 연결이 될 경우, 서로 묶여 있는 지식 요소들은 일종의 클러스터(cluster)를 형성한다. 이를 지식요소처럼 재귀적(recursive)으로 처리하면 더 복잡하고 추상적인 지식구조를 모델링할 수 있다. 즉, 지식 K_1 으로 K_2 를 만들수 있는데, K_2 는 K_1 의 지식요소 클러스터를 새로운 지식요소 단위로 가지는 그래프(노드와 연결)의 집합이다.

$$ALU(K_n) \xrightarrow{P_n, E_n} K_{n+1}$$

$$ALD(K_{n+1}) \xrightarrow{} K_n$$

Fig. 4. Abstraction level modification

Fig. 4에서 ALU는 K_n 지식으로부터 각 노드 점수 P_n 과 연결정보 E_n 을 이용하여 추상 수준을 한 단계 올리는 함수이다. 추상 수준을 내리는 ALD는 연결을 제거하여 노드 분해를 하므로 정보손실이 발생한다. 예를 들어, $K_{1=}\{'\mathbf{\Sigma}','\mathbf{dl}','\mathbf{n}','\mathbf{a}','\mathbf{a}'\}$ 최소단위의 지식요소로 구성된 지식 집합이라면, $K_2=\{[Seq.,['\mathbf{\Sigma}','\mathbf{n}','\mathbf{a}'],[Seq.,['\mathbf{\Sigma}','\mathbf{dl}','\mathbf{n}']]\}$ 는 단음 연주 패턴 지식이 된다. 만약, 화음을 연주하는 지식 정보라면 K_2 에서 Composition으로 지식 요소를 만든 후, 각각으로 K_3 에서 Sequence를 구성하면 된다. 그러므로, K_n 에서 \mathbf{n} 의 크기는 복잡도 또는 추상화 수준을 반영하면서 동시에 난이도와 연관된다.

3.2 학습 상태 및 컨텐츠 지식 모델링

Fig. 5는 학습 상태와 컨텐츠의 지식을 모델링하기 위해 앞서 정의한 지식요소와 이들의 관계를 일반화시켜 UML(Unified Modeling Language)로 설계한 클래스다이어그램이다. QueryManager는 물리적 데이터베이스 계층에 가장 가까운 계층으로 일종의 헬퍼(Helper) 클래스에 해당하기 때문에 지식 요소를 다루는 대부분의 클래스에서 직접적으로 사용한다. 다이어그램이 복잡해지는 것을 회피하기 위해 추가, 검색, 수정, 삭제 메소드를 가진 클래스는 CRUD 스테레오타입으로만 표시하였

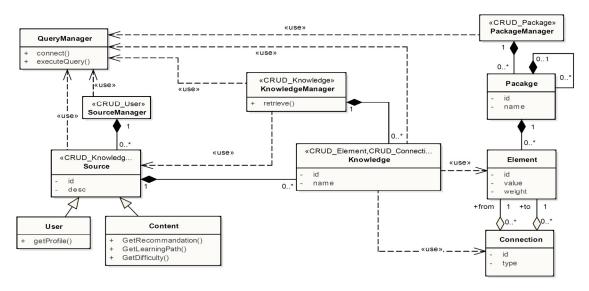


Fig. 5. A UML Class diagram for knowledge objects and simulation

다. 실질적인 분석 대상인 지식 요소와 관계는 Element 와 Connection 클래스 각각에 저장되며 Element의 상위 요소는 상속(inheritance)로 구현하지 않고, Connection 의 type 값을 기준으로 관계의 종류를 구분하였다. 이러한 방법으로 도메인에서 정의한 T 집합의 요소들을 그대로 매핑시킬 수 있다. 딥러닝의 뉴럴 네트워크는 학습된 가중치 값들의 조정을 통해서 연결 강도를 결정하는데, 결과적으로 만들어진 신경망의 해석이 어렵다는 단점이 있다. 본 연구의 경우도 이와 유사한 방식으로 단순한 구조로부터의 창발성(emergent property)을 이용하여 K_n 의 복잡도를 높일 수 있지만 가중치를 위한 연결 학습이 목적이 아니라 지식 정보의 누적 정도를 기록하기 위함이기 때문에 지식 요소들의 정보를 추적하여 의미 해석이 가능하다.

3.3 난이도 계산을 위한 알고리즘

Fig. 6은 맞춤형 난이도 척도를 계산하기 위한 알고리 즘이다. 난이도 계산을 위해서 임계치 이상의 점수를 가진 학습자의 학습 상태와 대상 컨텐츠의 지식 요소 각각에 대해 집합 연산을 적용함으로써, 이미 학습된 요소의 횟수 차이로 인한 난이도 차이를 제거해준다. 이러한 방식으로 지식의 차원별 또는 노드 및 관계 각각에 대한 학습 상태 그래프와 컨텐츠 지식 그래프의 차이(diff)를 구하게 되는데, 이 때 목표 컨텐츠의 학습 점수(LPoint)에서 학습 점수를 차감한다. 학습자의 지식이 컨텐츠의 기준을 넘는 경우는 0으로 계산한다.

```
\begin{array}{|l|c|c|c|c|} \hline & \textbf{Input:} \ (\text{a learner's knowledge}) \ K \\ \hline & \textbf{Input:} \ (\text{a contentsc' knowledge}) \ C \\ \hline & \textbf{Input:} \ (\text{depth of comparison}) \ n \\ \hline & \textbf{Output:} \ (\text{difficulty value}) \ d \\ \hline & d \longleftarrow 0 \\ \hline & \textbf{for } i \longleftarrow 1 \ \text{to} \ n \ \textbf{do} \\ \hline & K_i \longleftarrow \text{get\_KnowledgeLayer(i, K)} \\ \hline & C_i \longleftarrow \text{get\_KnowledgeLayer(i, C)} \\ \hline & LearningPoint_i \longleftarrow Diff(C_i, K_i) \\ & d \longleftarrow d + LearningPoint_i \end{array}
```

Fig. 6. Algorithm for personalized difficulty level calculation

```
Input: (a learner's knowledge ) K
Input: (a contents' knowledge ) C
Input: (threshold for similarity) t
Output: (a customized learning cost for C) lc
lc \leftarrow 0
posProcessed \leftarrow [\quad]
mp. sim = detectMatchPos(C,K,t)
for p in mp do
if p not in posProcessed
pointDiff \leftarrow max(C[p].LPoint - K[p].LPoint,0)
C[p].LPoint \leftarrow log(\sqrt{(pointDiff)})
posProcessed.append(p)
for p in posProcessed
lc \leftarrow lc + C[p].LPoint
```

Fig. 7. Algorithm for difference between knowledges and contents

Fig. 7은 *Diff* 함수에 대한 알고리즘이다. 일관성만 유지한다면 지식 요소 및 관계를 겹쳐서 만든 각각의 그래 프의 유사도를 비교하여 근사적으로 난이도를 계산할 수 있다. 하지만, 그래프 비교 알고리즘의 비용이 높기 때문에 여기서는 지식 요소별 계산 후 합산하였다.

4. 실험 결과 및 검증

검증 실험을 위해 음악 교육용 연주 컨텐츠 100개(지식요소 145,088개, 관계 508,857개), 학습자 20명(지식요소 42,351개, 관계 150,074개)에 대한 지식 상태를 시뮬레이션을 이용하여 생성하였다. Table 1은 실험 데이터 생성을 위한 조건의 평균값 및 표준편차(괄호안의 값)와 시뮬레이션을 통해 실제 생성된 데이터의 기초 통계정보를 보여준다. 생성 조건에서 key는 피아노 건반의 번호를 의미하며 element_size는 지식 요소 학습에 관여한 횟수이다. 즉, element_size가 클수록 시뮬레이션 과정에서 학습을 많이 할 가능성이 높아진다. 지식 상태는 1단계 지식 수준인 피아노 건반 번호와 이름, 그리고 화음을 표현하기 위한 컴포지션(composition) 관계인 2단계 추상화 수준까지 생성하였다.

Table 1. Initial and generated statistical information for content and user

		content	user
average of initial condition	center_key	42.5(10.2)	44.5(14.0)
	min_key	24.0(11.9)	27.8(17.1)
	max_key	59.8(12.4)	63.6(15.2)
	element_size	3112.5 (728.6)	7348.9 (1415.6)
total of generated data	count	100	20
	element	145,088	42,351
	relation	508,857	150,074

Fig. 8은 임계 조건 $\log(\sqrt{p}) > 1$ (p: 학습점수)을 만족하는 지식 상태라도 복잡도가 매우 높기 때문에 전체 시각화로는 분석이 불가능함을 보여준다. Fig. 9는 임계 조건 $\log(\sqrt{p}) > 1.5$ 를 만족하는 2단계 학습 관계 4,599개만으로 컨텐츠와 학습자의 지식 상태 정보를 시각화한 것이다. 학습 점수가 임계치 이상인 경우, 지식이 충분히학습되었다고 판단하고 학습 횟수 차이에 따른 큰 차이를 없애기 위해 Sigmoid 같은 극단적인 경우와 임계치를 넘기면 입력값을 출력으로 취하는 ReLu(Rectified)

Linear Unit)의 중간 정도의 효과를 내는 $\log(\sqrt{p})$ 를 이용하였다. 이러한 방법으로 학습 초기에는 학습 여부에 따라 점수 차이가 크지만, 일정 수준 이상에서는 차이가 크지 않도록 하였다.

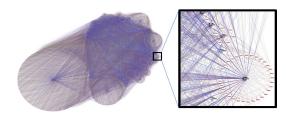


Fig. 8. Filtered relations among contents and users with condition $\log(\sqrt{p}) > 1$

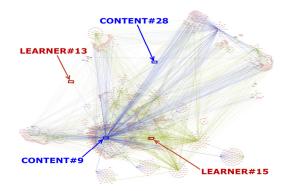


Fig. 9. Filtered relations among contents and users with condition $\log(\sqrt{p}) > 1.5$ (level2 only)

시각화 자료에서 개별 지식 요소들은 학습 점수를 가 진 연결에 따라 선 굵기와 색의 차이를 보인다. 녹색은 학습자, 회색은 컨텐츠를 나타내고 파란색은 1단계의 지 식 요소. 붉은색은 2단계의 지식 요소를 의미한다. 학습 자#9처럼 2단계 지식 요소와 강한 연결이 많은 학습자들 이 관찰되는데 이 경우는 해당 도메인 지식 수준이 상대 적으로 높다고 볼 수 있다. 반대로 컨텐츠#9처럼 2단계 지식 요소를 많이 가진 것은 그만큼 난이도가 높을 가능 성이 크다. 반면에 컨텐츠#28은 2단계 지식 요소를 주요 컨텐츠로 거의 가지지 않는다. 학습자#13처럼 충분히 학 습된 2단계 수준의 지식을 거의 가지지 못한 경우도 관 찰된다. 이러한 학습자에게는 대부분의 컨텐츠들의 상대 적 난이도가 높을 가능성이 크다. 컨텐츠와 학습자가 충 분히 연결된 지식 요소들끼리는 난이도 계산 과정에 서 로 상쇄되고, 그렇지 못한 컨텐츠 학습 요소들만 난이도 계산에 참여하게 된다. 그러므로, 상대적 난이도가 낮은

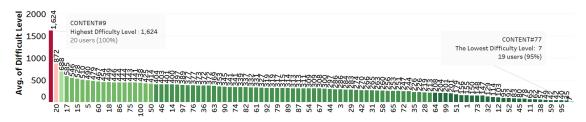


Fig. 10. Average Difficulty Levels of learners for each contents

컨텐츠를 검색하려면 컨텐츠의 학습점수를 형성하는 노 드 전체에서 해당 학습자의 지식요소들의 유사도가 반영 된 학습 노드의 비중을 줄인 그래프의 학습 점수를 계산 하면 된다.

Fig. 10은 100개의 컨텐츠에 대해 계산된 학습자들의 난이도를 평균한 데이터이며, Fig. 11은 각각의 학습자들 이 가지는 전체 컨텐츠에 대한 평균 난이도를 구한 결과 이다. 계산된 상대적 난이도는 Fig. 9에서 관찰했던 학습 자와 컨텐츠의 복잡도 상황과 일치한다.



Fig. 11. Average Difficulty Levels of contents for each users

20명의 학습자가 100개의 컨텐츠에 대해 느끼는 전체 난이도 평균은 307.0, 표준편차는 261.6이었으며 최소 1.2, 최대 2490.9로 큰 차이가 있었다. 가장 어려운컨텐츠는 #9로 학습자들의 평균 난이도는 1,624로 20명모두에게 100개 컨텐츠 중 가장 높은 난이도를 보였다. 대부분 컨텐츠 자체의 수준이 너무 높거나 낮으면 학습자별 차이가 크게 나타나지 않으며, 학습자 #6, #3, #12와 같이 학습 지식량이 적은 경우는 컨텐츠에 대해 계산된 난이도는 상대적으로 높았고, #15,#16과 같은 경우는 난이도 값이 낮았다. 학습자 #15의 경우 난이도가 가장 높은 컨텐츠 #9에 대해서 계산된 난이도는 916이었다. 이는 학습자 #6의 난이도 2,491의 37% 수준이었다.

Table 2는 학습자에 따라 동일한 컨텐츠라도 다르게 계산된 난이도의 경우를 보여준다. 대부분의 학습자들에게 컨텐츠 #5는 #14보다 난이도가 높지만, 학습자 #14에게는 반대로 컨텐츠 #14의 난이도가 더 높다. 마찬가지로, 학습자 #18의 경우도 컨텐츠 #28과 #31에 대해

유사한 상황이 발생한다. 이는 학습자 #14와 #28이 각 각 컨텐츠 #5와 #31와 관련한 지식을 이미 습득하거나 실제로 해당 컨텐츠를 일부 학습했기 때문일 것으로 판 단할 수 있다.

Table 2. Examples: personalized difficulty level

CONTENT LEARNER	#5	#14	#28	#31
#9	517	356	235	267
#14	370	398	227	275
#18	415	320	166	121
#20	402	324	173	233

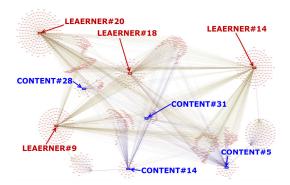


Fig. 12. Partial Knowledge State of CONTENT #5,#14, #28,#31 & LEARNER #9,#14,#18,#20 with condition $\log(\sqrt{p}) > 1.5$

Fig. 12는 Table 2의 컨텐츠와 학습자 지식 상태를 $\log(\sqrt{p}) > 1.5$ 조건으로 나타낸 그래프를 보여준다. 실제로는 보다 복잡한 관계들이 있기 때문에 필터링을 통해주요 학습 요소들에 대해서만 표현한 것인데, 컨텐츠에 대한 학습자들의 지식 연결의 상대적 차이를 시각적으로 확인할 수 있다.

5. 결론

맞춤형 교육을 위한 학습 상태 모델을 제안하여, 이를 기반으로 학습자와 컨텐츠의 지식 상태를 구현하고 난이도 척도를 계산하여 분석하였다. 실험 결과, 학습자의 평가 참여를 통해 난이도를 계산하거나[1-4] 콘텐츠 자체의 난이도를 절대적 방식으로 산정한 비맞춤형 난이도 연구[8]와는 달리 학습자와 컨텐츠의 지식 상태를 정적으로 분석하여 유의미한 상대적 난이도를 계산할 수 있었다. 다만, 학습자와 컨텐츠의 수가 증가할 경우 학습 상태모델의 복잡도가 매우 높아질 수 있기 때문에, 본 연구의성과를 효과적으로 활용하기 위해서는 이를 효율적으로처리하기 위한 컴퓨팅 자원과 지속적으로 학습자의 학습정보를 추출할 수 있는 온라인 교육 플랫폼 연계 등의 솔루션이 필요하다.

본 연구에서 제안하는 학습자의 학습 상태 추적과 맞춤형 난이도 척도의 품질은 지식 학습 점수의 정확도와학습자의 학습 지식 커버리지 신뢰도에 종속된다. 하지만, 지식 학습 점수는 모든 학습자가 동일한 환경에 있다면 일관성이 유지되므로 상대적 비교에 있어서는 어느정도 정확도를 보장할 수 있으며, 문제 풀이 및 과제, 온라인 활동 등을 통해 지속적 갱신이 가능하다. 또한, 학습지식 커버리지의 경우, 초기에는 신뢰도가 낮더라도 반복적으로 컨텐츠를 접하게 되면서 학습자의 참여 로그 등을 이용하여 신뢰도를 높일 수 있다. 향후에는 이러한 품질 개선 요소들을 관리하는 인프라를 모두 포함한 맞춤형 교육 전체 플랫폼을 설계할 계획이다.

REFERENCES

- S. Y. Heo & E. G. Kim. (2010). SCORM-based Contents Organization System on Learners' Level. *The Korea Institute of Information and Communication Engineering*, 14(5), 1277-1283.
 DOI: 10.6109/JKIICE.2010.14.5.1277
- [2] C. H. Kim, H. D. Ko & B. K. Kim. (2005). Item Difficulty Analysis of Learning Contents Based on SCORM. Proceedings of the Korean Information Science Society Conference. (pp. 358-360). Seoul: KIISE.
- [3] A. Baylari & G. A. Montazer. (2009). Design a personalized e-learning system based on item response theory and artificial neural network approach. Expert Systems with Applications, 36(4), 8013-8021.

DOI: 10.1016/J.ESWA.2008.10.080

- [4] H. J. Lee & S. T. Park. (2015). Analysis on Knowledge State of Inquiry Abilities of Elementary School Students on Electric Circuits. *Journal of The Korean Association for Science Education*, 35(5), 857-870. DOI: 10.14697/JKASE.2015.35.5.0857
- [5] M. B. Yoon. (2011). Investigating the Effects of Teaching Bassed on an Analysis of High School Students' Knowledge State of Concepts Associated with Astronomical Observation. *Journal of the Korean Earth Science Society*, 32(7), 902-912. DOI: 10.5467/JKESS.2011.32.7.902
- [6] J. H. Lee. (2017). Knowledge State Analysis of the Elementary School Plane Figure unit Using the Knowledge Space Theory. Asia-pacific Journal of Multimedia Services Convergent with Art, Humanities, and Sociology, 7(5), 13-31. DOI: 10.14257/AJMAHS.2017.05.08
- [7] P. Gao. (2014). Using Personalized Education to Take the Place of Standardized Education. *Journal of Education and Training Studies*, 2(2), 44-47. DOI: 10.11114/JETS.v2i2.269
- [8] I. S. Choi. (2005). A Comparative Study on Modeling Readability Formulas: Focus on Primary and Secondary Textbooks. *Journal of the Korean Society* for information Management, 22(4), 173-195. DOI: 10.3743/KOSIM.2005.22.4.173
- [9] Chih-Ming Chen. (2008). Intelligent web-based learning system with personalized learning path guidance. *Computers & Education*, 51(2), 787-814.
 DOI: 10.1016/I.COMPEDU.2007.08.004
- [10] W. Jung. (2019). A Genetic Algorithm Based Learning Path Optimization for Music Education. *Journal of the Korea Convergence Society*, 10(2), 13-20. DOI: 10.15207/JKCS.2019.10.2.013
- [11] J. Han, J. Jo & H. Lim (2018). Development of Personzlied Learning Course Recommendation Model for ITS. *Journal of the Korea Convergence Society*, 9(10), 21-28. DOI: 10.15207/IKCS.2018.9.10.021
- [12] T. Cho (2016). Intelligent learning system based on the profile of learner. *Journal of Digital Convergence*, 14(2), 227–233.
 DOI: 10.14400/JDC.2016.14.2.227
- [13] M. A. Chatti & A. Muslim. (2019). The PERLA Framework: Blending Personalization and Learning Analytics. *International Review of Research in Open* and Distributed Learning, 20(1), 243–261. DOI: 10.19173/IRRODL.v20i1.3936
- [14] A. Ramachandran & B. Scassellati. (2014). Adapting Difficulty Levels in Personalized Robot-Child Tutoring Interactions. AAAI Conference on Artificial Intelligence. (pp. 56-59). USA: AAAI.
- [15] A. Jones & G. Castellano. (2018). Adaptive Robotic Tutors that Support Self-Regulated Learning: A Longer-Term Investigation with Primary School

Children, International Journal of Social Robotics, 10(3), 357-370.

DOI: 10.1007/s12369-017-0458-z

- [16] F. Essalmi, L. J. E. Ayed, M. Jemni, S. Graf & Kinshuk. (2014). Generalized metrics for the analysis of E-learning personalization strategies. Computers in Human Behavior, 48(1), 310-322. DOI: 10.1016/J.CHB.2014.12.050
- [17] K. Kim & H. Shin (2016). Student-oriented Multi-dimensional Analysis System using Educational Profiling. Journal of Digital Convergence, 9(10), 263-270.

DOI: 10.14400/JDC.2016.14.6.263

[18] R. Reber, E. A. Canning & J. M. Harackiewicz. (2018). Personlized Education to Increase Interest. Current Directions in Psychological Science, 27(7), 449-454. DOI: 10.1177/0963721418793140

정 우 성(Jung, Woosung)

[종신회원]



· 2003년 2월 : 서울대학교 컴퓨터공학 과(공학사)

· 2011년 8월 : 서울대학교 컴퓨터공학 과(공학박사)

· 1998년 9월 ~ 2002년 2월 : SK 유비 케어 연구원

· 2011년 9월 ~ 2012년 2월 : LG전자

CTO 선임연구원

· 2012년 3월 ~ 2016년 8월 : 충북대학교 교수 · 2016년 9월 ~ 현재 : 서울교육대학교 교수

· 관심분야 : SW교육, SW공학, SW저장소 마이닝, AI융합

· E-Mail: wsjung@snue.ac.kr