

맞춤형 영어 교육을 지원하기 위한 콘텐츠 기반 분석 기법

정우성¹, 이은주^{2*}

¹서울교육대학교 교육전문대학원 교수, ²경북대학교 컴퓨터학부 부교수

Analysis technique to support personalized English education based on contents

Woosung Jung¹, Eunjoo Lee^{2*}

¹Professor, Graduate School of Education, Seoul National University of Education

²Associate Professor, School of Computer Science and Engineering, Kyungpook National University

요약 인터넷 기술과 모바일 등의 기기 발전으로 교육환경도 전통적이고 수동적인 방식에서 학습자 중심의 능동적인 방식으로 변화하고 있다. 이에 따라 학습자 개인의 수준별 맞춤 교육의 역할도 커지고 있으며, 이에는 개별 학습자의 프로파일 구축이 중요하다. 기존의 ICT 기반 맞춤형 영어 교육의 다수는 어휘에 초점을 맞추고 있으며, 학습 콘텐츠에 대한 분석에 많은 노력을 기울이고 있다. 본 논문에서는 보다 정밀하게 사용자의 학습상태를 정의하기 위하여 단어와 문법을 대상으로 학습 상태를 구축하였다. 그리고 학습자가 특정 콘텐츠에 얼마나 익숙한지를 알려주는 콘텐츠에 대한 숙련도 메트릭을 정의하였다. 이후 실제 영문 에세이 데이터를 기반으로 사전학습을 통하여 사용자들의 숙련도를 결정하고, 시뮬레이션을 통하여 평가 에세이 데이터에 대하여 적용성이 있음을 보였다. 또한 본 연구에서 제안한 분석기법은 학습상황에 대하여 통계치나 그래프를 제공하고 학습자 수준에 적합한 학습자료를 생성하는데 필요한 데이터를 제공할 수 있다.

주제어 : 영어 교육, 맞춤형 교육, 숙련도, 문법, 어휘, 학습자 프로파일

Abstract As Internet and mobile technology is developing, the educational environment is changing from the traditional passive way into an active one driven by learners. It is important to construct the proper learner's profile for personalized education where learners are able to study according to their learning levels. The existing studies on ICT-based personalized education have mostly focused on vocabulary and learning contents. In this paper, learning profile is constructed with not only vocabulary but grammar to define a learner's learning status in more detailed way. A proficiency metric is defined which shows how a learner is accustomed to the learning contents. The simulational results present the suggested approach is effective to the evaluation essay data with each learner's proficiency that is determined after pre-learning process. Additionally, the proposed analysis technique enables to provide statistics or graphs of the learner's status and necessary data for the learner's learning contents.

Key Words : English education, Personalized education, Proficiency, Vocabulary, Grammar, Learner profile

*This work was supported by the 2021 Research Fund of Seoul National University of Education.

*Corresponding Author : Eunjoo Lee(ejlee@knu.ac.kr)

Received January 20, 2022

Revised January 28, 2022

Accepted March 20, 2022

Published March 28, 2022

1. 서론

인터넷과 모바일, 인공지능 등의 기기 및 기술 발전으로 인하여 전통적인 교육환경도 빠르게 변화하고 있다. 학습자들은 기존의 수동적인 방식에서 능동적인 방식으로, 하향식에서 상향식으로, 교육기관 내부에서 교육기관 외부로 확대되고 있다[1]. 이러한 환경 변화에는, 일률적인 주입식 교육에서 학습자 개인의 수준별 맞춤 교육도 큰 부분을 차지하고 있다. 이를테면 학습 콘텐츠의 난이도가 기존에는 콘텐츠 제공자가 획일적으로 정하는 것이었다면, 맞춤형 방식에서는 학습자의 관심도와 경험에 맞추어 난이도를 결정할 수 있다[2].

개별 학습자의 프로파일에 따라 자동적으로 적절한 콘텐츠를 찾아서 추천할 수 있는 것은 학습 시스템의 가장 중요한 역할로 볼 수 있다[3]. 여기서 학습자 프로파일은 개인의 학습 진도, 수준 및 역량에 대한 정보를 담고 있는 데이터로서, 효율적인 맞춤형 교육을 위한 핵심적인 요소라고 할 수 있다[4].

다양한 분야에서, 변화된 교육환경에서 학습자 중심 교육을 지원하기 위한 연구들이 수행되었다. 그 중 영어 교육에서도 ICT(Information and Communication Technology)의 이용이 증대되고 있으며 [5], 모바일앱 등에서의 영어 교육과 관련한 다양한 연구들이 수행되었다. 실제로 수업 맞춤형 모바일 앱을 사용하는 것이, 특히 하위 학습자들에게는 의미가 있다는 연구결과도 존재한다[6].

ICT기반 맞춤형 영어 교육과 관련하여 다수의 연구들이 수행되었다. 맞춤형 모바일 앱의 유용성을 입증하거나[6], 단어 학습이나 문법 학습을 지원하는 데 초점이 맞추어져 있다. 특히 문법 보다는 단어 학습 관련 연구들이 활발히 진행되고 있다. 문장 복잡도 메트릭을 이용하여 학습할 단어를 추천하거나[7], 사용자의 수준과 시간 정보를 이용하여 각 단어에 점수를 부여하는 기법을 제안하였고[8], 단어 학습에 자기조절 메커니즘 도입의 유용함을 보였다[9]. 문법 문항들 사이의 유사도를 측정하여 맞춤형으로 문제를 추천할 수 있도록 하거나 [10], 문법 학습에서도 자기조절 학습 메커니즘을 적용한 사례를 보였다[11]. 기존 연구들에서는 학습 콘텐츠에 대한 분석에 집중을 하는 경향이 있으며, 사용자의 입력을 주요 데이터로 활용을 하고 있으므로, 보다 정밀하게 사용자의 학습 및 습득 상태를 정의하여 이용할 필요가 있다.

본 논문에서는 맞춤형 영어 교육을 지원하기 위하여 콘텐츠에 기반한 분석기법을 제안하였고, 실험을 위해 사전 학습 과정을 시뮬레이션하였다. 학습 대상은 단어와 문법을 반영한 품사 시퀀스이며, 이를 추상화한 지식 집합으로 구성하여 학습자의 학습 상태를 표현하였다. 학습자별 학습 차이를 반영하기 위해 학습자의 학습률, 학습 노이즈 편차, 학습 완료 임계치, 학습 대상 난이도 등의 파라미터를 설정하였다. 지식 집합의 커버리지를 이용하여 학습자의 콘텐츠에 대한 숙련도 메트릭을 정의하였다. 숙련도 메트릭은 차후 학습할 콘텐츠에 대하여 학습자가 얼마나 익숙한지를 알려주므로 맞춤형 콘텐츠 추천에 필요한 척도라고 할 수 있다. 이후, 시뮬레이션을 통하여 각기 다른 프로필을 가진 가상의 학습자 4인에 대하여 실제 영문 에세이 데이터를 이용하여 사전 학습하여 숙련도를 분석하고, 이후 학습할 콘텐츠에 대한 숙련도를 예측하고, 학습에 필요한 어휘나 문법 패턴을 추출함으로써 맞춤형 교육 자료 생성에 활용할 수 있음을 보였다.

본 논문의 이후 구성은 다음과 같다. 2장에서는 일반적인 맞춤형 교육 관련 연구들과 ICT 기반 영어 교육 관련 연구 현황에 대하여 소개한다. 3장에서는 본 연구에서 수행한 연구 방법을 설명한다. 4장에서는 실험 결과에 대한 분석 및 활용을 보이며, 5장에서 결론을 맺는다.

2. 관련 연구

맞춤형 교육을 위하여 교육 프로파일링을 활용하여 다차원 분석 시스템을 제공하거나[12], 학습자의 스타일을 고려하여 적응형으로 콘텐츠를 추천해주는 연구가 진행되었다[3]. Kim 등은 학생에 대한 맞춤형 지도가 총점 중심으로 이루어져 개인의 환경에 대한 고려가 부족하다고 지적하고, 이를 위하여 전문적인 통계 지식이 없어도 운영할 수 있는 성적 맞춤형 통계 분석 시스템을 제안하였다[12]. 제안된 시스템은 학생들의 과목별 성적에 기반하여 빈도분석, 교차분석, 기간별 분석, 다항 분석을 수행한다. 제안된 시스템은 의미 있는 학습자 프로파일을 구축하여 맞춤형 교육에 적용하고자 한다는 점에서는 본 연구와 유사하나, 일반적인 학생 데이터와 성적을 이용하여 학습자 프로파일링을 하므로, 영어를 대상으로 하는 본 연구와는 목적이 다르다. Nafea 등은 협력 필터링(collaborative filtering)과 아이템 콘텐츠 필터링을 통하여 맞춤형 콘텐츠를 추천해주는 시스템

ULEARN을 제안하였다[3]. Nafea 등은 기존 추천 시스템에서는 학습 콘텐츠에 초점을 맞추므로, 학습자의 선택과 입력에 대한 고려가 부족하다고 주장하였다. 이를 보완하기 위하여 ULEARN에서는 개별 학습자 프로필에 부합하는 티칭 전략을 추천해주는 협력 필터링 기법과 학습자의 평가에 기반하여 추천해주는 콘텐츠 필터링 기법을 결합하였다. 학습 방식 모델에 관하여 FLSM (Felder Silverman Learning Style Model)[13]이 가장 안정적이고 적합한 적응형 하이퍼미디어 학습 시스템용 모델이라는 주장[14]에 근거하여, FLSM에 기반하여 학습 스타일과 관련한 문항들을 제안하고 학습자가 입력을 하도록 한다. 이것이 초기 학습자 프로필이 되며, 이후 학습자가 학습해 나가면서 수정 보완이 이루어진다. 학습자 프로필에 따라 티칭 방식이 추천되고, 추천된 티칭 방식에 적합한 학습 대상을 연결시킨다.

ICT 기반 영어 교육과 관련하여 여러 연구들이 수행되었다. Kim은 수업 맞춤형 모바일 앱을 사용하는 것이 수준별 학습자들의 영어 실력 향상에 미치는 영향을 분석하였고, 결과적으로 맞춤형 앱이 상위 학습자보다 하위권 학생들에게 유익하다고 주장하였다 [6]. 맞춤형 방식의 유용함을 실험 결과로 보여주었다는 점에서 의미가 있으나, 사용된 맞춤형 앱에서는 각 수업의 주제에 따라 관련된 콘텐츠를 제공하고 있으므로, 맞춤형의 의미가 학습자가 아니라 학습할 주제라는 점에서 본 연구의 방향과는 차이가 있다.

영어 교육 분야에서 어휘(vocabulary)와 관련된 연구들이 다수 수행되었다[7-9]. [7]에서는 영어 공부에 있어 상대적으로 어휘가 중요하다는 전제하에, 단어 난이도와 문장 복잡도 메트릭을 이용하여 맞춤형 어휘 학습 추천 시스템을 제안하였다. 이들은 단어 길이, 발음 길이, 단어 난이도, 문장 내 단어 빈도, 문장 내 읽은/읽지 않은 단어 빈도, 문장 내 단어 의존 거리, 새로운 단어 점수, 새로운 단어 빈도 점수, 문장 복잡도 점수, 문장 길이 등 기존 연구들에서 부분적으로 사용하던 파라미터들을 활용하거나 다시 정의하여 문장 점수 메트릭을 제안하였다. [8]에서는 유비쿼터스 환경에서 맞춤형된 영어단어 학습을 지원해주는 시스템을 제안하였다. 이들은 기존의 정보 함수 기법(information function method)을 이용하여 학습자의 수준에 따라 정해진 각 단어의 정보값과, 퍼지(fuzzy) 이론을 이용하여 특정 단어와 관련된 시간 특성을 정의한 다음, 두 요소를 결합

하여 각 단어의 점수를 결정하였다. 시간특성을 정한 이유는, 기본적으로 단어들은 그 단어와 연관된 때에 학습이 유리하다고 판단하였기 때문이다. 적응적으로 단어의 점수를 조정하는 것은 의미가 있으나, 단어의 유형에 따라 시간 이외에도 다른 의미적인 상황을 고려할 수 있을 것이다. Chen 등은 자기조절 학습 메커니즘(SRLM: self-regulated learning mechanism)을 도입한 영어 단어 학습 앱이 학습에 중요한 영향을 미치는 것을 실험을 통하여 보였다[9]. 자기조절학습(이후 SRL로 칭함)은 스스로에 대해 파악하고 동기부여를 하며 행동방식을 조절하여 학습을 하게 되는데, 이들은 영어단어 학습에서 SRL을 적용한 사례가 많지가 않다고 주장하였다. [9]에서는 영어 단어 학습 앱에서 SRL방식을 적용하였는데, 하루에 배울 단어의 수, 노트의 수, 연습문제의 수 등을 정하도록 하고, 적절한 목표를 제시해주었고, 결론적으로 SRLM방식을 적용한 경우가 학습적으로 더 나은 결과가 나왔다.

영어학습 분야에서 어휘, 읽기, 말하기에 비해 문법 학습에 대한 관심이 부족한 상황에서, 맞춤형 문법 문제 추천[10], 모바일 맞춤형 영어 문법 학습 지원기법[11]이 제안되었다. 기존의 콘텐츠 유사도 측정방식으로는 문법 문제들 사이의 유사도를 측정하기가 어려우므로 Fang 등은 파스-키 트리(parse-key tree)구조를 바탕으로 문법 문항들 사이의 유사도를 측정하는 세 척도인 파스-키 트리 유사도, 개념 유사도, 텍스트 유사도를 개발하였다[10]. 이 유사도를 바탕으로 데이터베이스를 검색하여 질의로 들어온 문법 문항과 유사한 문항들을 추천해준다. Wang 등은 자기조절(self-regulated) 학습 메커니즘에 따라 모바일기기에서 맞춤형으로 영어 문법 학습을 도와주는 기법을 제안하였다[11]. 제안된 기법에서는 학습자의 피드백, 학습 목표와 이전 성취에 기반한 추천, 학습이력을 포함하는 포트폴리오를 이용하고 있다.

3. 연구 방법

3.1 개요

본 연구는 맞춤형 영어 교육을 지원하기 위한 콘텐츠 기반 분석 및 학습 시뮬레이션에 관한 연구로 Fig. 1과 같은 구조를 따라 진행하였다. 학습률, 마스터 임계치 등 개별 파라미터 설정에 따라 학습 시뮬레이션을 위한 학습자 객체를 생성하고, 350편의 에세이 중 70편과 기초

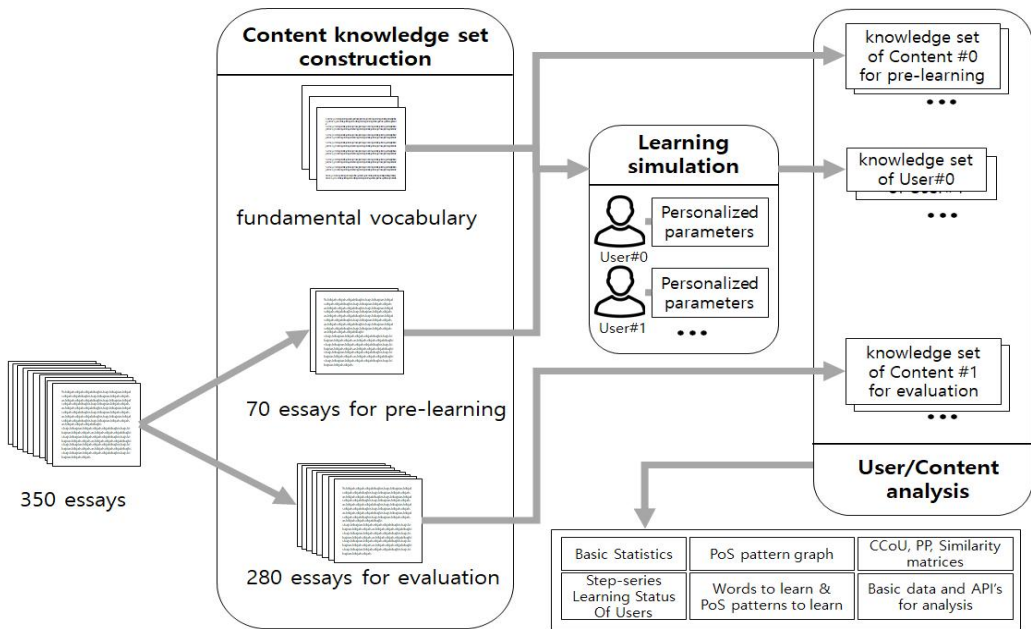


Fig. 1. The overall structure of our proposed approach

어휘 목록을 사전 학습시킴으로써 학습자별로 개별화된 지식 집합을 구축하였다. 이는 분석 과정에서 학습자들의 학습 상태를 구분하기 위한 기초 데이터로 활용된다. 나머지 280편의 에세이는 학습자 객체의 입장에서 맞춤형 숙련도 메트릭을 예측 계산하고 콘텐츠 내용을 실제로 비교 분석하여 본 연구에서 제안한 접근법을 검증하기 위한 용도로 사용하였다.

콘텐츠, 학습자, 분석기 클래스는 논문에 포함된 실험의 개별화된 분석을 용이하게 하기 위하여, 추가 데이터 구조와 API가 제공되도록 설계하였다. Fig. 2에서 제시한 클래스 다이어그램은 본 연구에서 사용한 주요 개체와 이들의 속성 및 메소드, 관계에 대한 정적 구조를 보여준다.

Content 객체는 개별 에세이 파일로부터 생성되며, 고유 아이디, 카테고리, 파일 경로, 전체 텍스트, 문장 리스트와 토큰, 품사에 대한 n-gram 분석 결과 데이터를 속성으로 가지게 되며, 객체가 생성되면서 함께 속성값이 결정된다.

User 객체는 학습 시뮬레이션 과정에 필요한 학습의 주체로서 학습률, 노이즈 편차, 마스터 임계값 등을 가지며 기본적인 토큰, 품사에 대한 n-gram 분석 결과 데이터를 동일한 LObject의 속성을 상속받아 가지게 된다. 또한, 학습을 마스터한 토큰과 품사 n-gram에 대한

정보를 별도로 속성으로 가진다.

Analyzer는 학습 시뮬레이션과 분석에 필요한 여러 메소드들을 가지고 있으며, 실험에 관여하는 콘텐츠와 학습자 객체를 리스트로 가지게 된다. 추가적으로, 글로벌 토큰과 품사에 대한 n-gram 분석의 통합된 집합도 관리하며, 그래프나 엑셀 생성 관련 메소드가 포함된다.

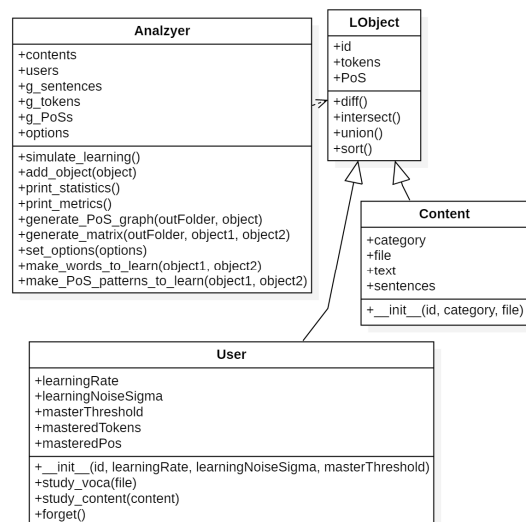


Fig. 2. Class diagram of major objects for our proposed approach

3.2 숙련도 점수 PP(Proficiency Point)

본 연구에서 다루는 콘텐츠와 학습자의 전체 집합을 각각 C , U 라고 하고, 자연수 i, j, k 가 해당 도메인에서의 고유한 구분자라고 했을 때 각각의 콘텐츠 $c_i \in C$ 와 학습자 $u_j \in U$ 에 대하여 $Type(k)$ 기준에서 u_j 의 c_i 에 대한 지식 집합(knowledge set) 커버리지 $CCoU$ (Contents Coverage of User)를 다음과 같이 정의한다.

$$CCoU_{Type(k)}(c_i, u_j) = \frac{|c_i.KSet_{Type(k)} \cap u_j.KSet_{Type(k)}|}{|c_i.KSet_{Type(k)}|}$$

이 때, 숙련도 계산에 사용할 지식 집합의 타입이 n 가지 인 경우 c_i 에 대한 u_j 의 숙련도 점수 PP 를 다음과 같이 정의한다.

$$PP(c_j, u_j) = \sum_{k=1}^n w_k \times CCoU_{Type(k)}(c_i, u_j)$$

이 경우, w_k 는 숙련도 평가에서 $KSet_{Type(k)}$ 의 가중치로 $\sum_{k=1}^n w_k = 1$ 이어야 한다. 그러므로, $CCoU$ 의 범위는 항상 $0 \leq CCoU \leq 1$ 이 되며, 1인 경우는 사용자의 n 개 관점에서의 지식 집합이 콘텐츠를 포함하므로 숙련도가 최대값을 가지며, 0인 경우는 사용자의 지식 집합이 콘텐츠에 포함되는 것이 없으므로 최소값을 가지게 된다.

본 연구에서 정의한 영문 콘텐츠에 대한 숙련도 점수 PP_E 는 어휘와 문법 요소의 가중치를 절반씩 반영하였다. 문법 요소는 품사의 n -그래프($n=1,2,3$) 패턴을 반영하여 다음과 같이 3단계로 구분하였으며, 패턴의 길이에 비례하여 가중치를 주었다. 즉, $KSet_{Type(1)}$ 은 콘텐츠에 등장하는 단어들로부터 추출한 어간 집합에 해당하며, $m=2,3,4$ 일 때 $KSet_{Type(m)}$ 은 $m-1$ 그래프 PoS[16] 패턴 집합에 해당한다. 단어와 문법 지식에 대한 반영이 동일하게 이루어질 수 있도록 $w_1 = 6/12$, $w_2 = 1/12$, $w_3 = 2/12$, $w_4 = 3/12$ 를 할당하였다.

3.3 학습 시뮬레이션 및 분석

숙련도 점수를 계산하기 앞서 콘텐츠에 대한 학습자의 학습이 이루어져야 하며, 학습된 상태는 단어와 문법의 추상화된 지식 집합으로 구성됨을 가정하였다. 본 연구

에서는 5개 등급으로 나뉘어 있는 850개 단어장[15]과 교육부에서 제시한 2015 개정 영어과 교육과정[17]에 실려 있는 기본 어휘 3,052개를 별표로 구분된 난이도를 반영하여 사전 학습 시뮬레이션 데이터로 활용하였다.

본 연구에서 구현한 영어 맞춤형 교육 분석 도구는 실험자가 추가적으로 필요한 어휘나 글이 포함된 파일 경로를 파라미터로 전달하여 User 객체별로 `study_voca()` 또는 `study_content()`를 반복 실행함으로써 개별 학습이 가능하다. 본 연구의 목적은 학습 시뮬레이션의 모방이 아니라, 학습자의 어휘나 문법 지식 집합의 상태를 구분하고 이를 기반으로 맞춤형 교육에 필요한 콘텐츠 분석을 하는 것이 목적이므로, 사전 학습 데이터를 임의로 정하여 사용하더라도 실험의 일반성을 저해하지 않는다.

```

Input: (list of users)  $U$ 
Input: (list of voca. files order by grade)  $V$ 
Input: (list of contents)  $C$ 
Input: (iteration count)  $n$ 
Output: (list of updated users)  $U'$ 

for  $u \in U$  do
  for  $v \in V$  do
    for  $i \leftarrow 1$  to  $n$  do
       $u.study\_voca(v)$ 
    for  $c \in C$  do
      for  $i \leftarrow 1$  to  $n$  do
         $u.study\_content(c)$ 

```

Fig. 3. Pseudocode for overall learning process

학습자 학습은 Fig. 3에서 제시한 절차를 따라 이루어지며, 기본 어휘를 먼저 반복 학습한 후, 문법 패턴을 포함한 콘텐츠를 반복 학습하게 된다. 객체 리스트로 전달할 경우, 동일한 내용과 반복 조건으로 모든 학습자 객체의 학습이 이루어지게 되지만 학습자의 학습물이나 마스터 임계치 등의 개별 설정에 따라 학습 상태의 차이를 나타나게 된다.

학습 시뮬레이션에서는 Table 1과 같은 설정으로 4개의 학습자 객체를 생성하였다. 학습물과 임계치 등 실험에 필요한 파라미터는 학습자별 학습 상태를 차별화하기 위한 것이므로 구현이나 데이터의 상황에 따라 상대적으로 차이가 나도록 실험 결과의 통계치를 기준으로 선택할 수 있다.

Table 1. Parameters for user objects

user#	learning Rate	learning NoiseSigma	master Threshold
1	0.4	0.4	30
2	0.5	0.5	25
3	0.7	0.7	20
4	1.0	1.0	10

학습자 4번의 경우는 학습 내용을 완벽히 마스터할 정도의 수준으로 학습률과 임계치를 설정하였고, 학습자 3번은 대부분 마스터할 수 있는 정도로 설정하였다. 학습자 1,2번은 비교적 낮은 학습률과 높은 마스터 임계치를 주어 반복적으로 등장하는 일반적인 어휘나 문법 중심으로만 학습이 이루어지도록 하였다. 모든 학습자 객체는 어휘 학습을 마친 후, 0~349번 에세이 중 5의 배수에 해당하는 0.5, 1.0, ..., 345번 에세이 70개를 사전 학습하게 되며, 이 과정에서 일부 기존 어휘의 학습 상태를 강화하고, 추가 어휘나 문법 패턴 지식을 습득하게 된다.

학습에 사용할 콘텐츠 객체 생성 시에는 파일 경로만 지정하면 일련번호로 id를 지정하고 해당 파일의 텍스트로부터 문장을 우선 추출한다. 다시 개별 문장을 기준으로 추출한 토큰, 어간, 품사 정보를 지식의 최소 단위로 사용하기 위해 n-gram 패턴의 키(key)로 지정함으로써 빈도를 계산하고, 다른 객체에 대한 역 인덱스를 생성할 수 있도록 하였다. 또한, 빈도를 기준으로 지식 요소들을 정렬하고, 콘텐츠 또는 사용자가 학습한 지식 집합들 사이에서 이루어질 수 있는 모든 n-gram 패턴에 대한 연산을 메소드로 구현하였다. 이는 지식 집합 커버리지나 속련도 계산, 학습이 필요한 어휘나 문법 추출 과정에서 사용하는 집합 기반 정의를 코드에서 쉽게 호출하여 사용할 수 있다는 장점을 제공한다.

학습자 객체의 경우는 생성 과정에 id 외에도 학습률(learningRate), 학습노이즈편차(learningNoiseSigma), 완전학습임계값(masterThreshold)을 파라미터로 받는다. 학습자의 지식 집합 구조는 콘텐츠와 동일하게 구성 되어 있지만, study_voca() 함수의 파라미터로 학습할 파일경로를 입력받으면, 어휘의 해당 학습자 객체의 파라미터를 통해 학습 속도나 망각 정도가 반영되어 시뮬레이션 되도록 하였다. 또한, 단어장에 표시된 별표 등을 기준으로 학습 과정에 약간의 패널티가 반영되도록 가중치를 조정하였다. study_content()는 콘텐츠 객체를

파라미터로 받아서 학습하는 메소드로 study_voca()와는 달리 문법 요소를 추가적으로 학습에 반영한다. 학습 1회만으로는 콘텐츠가 담고 있는 모든 지식을 가져올 수 없기 때문에, 반복 학습을 통해 학습률, 난이도 등의 영향을 받아 확률적으로 난이도가 낮은 지식 요소가 masterThreshold에 우선 도달하게 된다. 이러한 과정을 통해 학습자 객체의 지식 요소가 학습 완료 상태로 변환된다.

Analyzer 도구는 학습 단계에 따라 학습 완료에 도달한 단어 및 문법 상황 데이터를 엑셀 또는 그래프로 출력하거나, 콘텐츠별 지식 요소들의 빈도 벡터 시각화, 지식 요소에 기반한 유사도 매트릭스를 제공할 수 있다. 뿐만 아니라, 학습자의 수준을 기준으로 특정 콘텐츠를 학습하기 위해 알아야 할 지식 요소, 즉 학습자 수준에 맞는 단어나 문법 패턴으로 맞춤형 학습자료를 생성하는데 필요한 기초 데이터를 제공할 수 있다

4. 실험 결과 분석 및 활용

본 연구에서는 3장에서 정의한 접근법에 대한 실험을 위해 총 8,932개 문장 패턴을 가진 350편의 에세이를 사용하였다. 단어 패턴의 개수는 15,266개로 어간 추출(stemming) 후 11,118개였으며, 2-gram 단어 패턴은 79,332개로 어간 추출 후에는 73,886개였다. 품사 패턴은 문장 속에 등장한 특수 문자를 함께 고려하여 42개였고, 2연속 품사 시퀀스 패턴은 1,025개였다.

Table 2. The counts of n-gram patterns from 8,932 statements in 350 essays

	1-gram	2-gram	3-gram
word	15,266	79,332	128,188
word(stemmed)	11,118	73,886	126,571
PoS	42	1,025	8,972

Table 2에서 회색으로 음영처리된 범위는 실험에 사용한 데이터의 크기를 보여주며, 앞서 3장에서 정의한 PP 분석을 위해 추출한 어간과 품사의 시퀀스의 개수에 해당한다.

Fig. 4는 실험에 사용한 350개 에세이 각각에서 등장하는 단어들 상위 10%와 하위 10%에서의 분포, 즉 DF(document frequency)를 시각화시킨 결과이다.




Fig. 4. Token distribution graph of the 350 essays

열은 어휘, 행은 350개의 에세이에 해당한다. 상위 어휘들은 'the', 'I', 'and', 'to', 'of', 'a', 'in', 'my', 'that' 등으로 자연스럽게 다양한 콘텐츠를 통해 반복 학습되는 단어들이며, 하위 어휘들은 어휘력이 약한 학습자에게는 상대적으로 생소할 수 있는 'colm', 'autobiography', 'hairdo', 'mainstream', 'mocking', 'bleak' 등과 같은 어휘들이 분포하였다. 문법 패턴도 Fig. 4와 유사한 분포를 보였으며, 상위 문법 패턴은 주로 IN, DT, NN 등으로 구성된 흔한 조합이었고 하위 문법 패턴은 VBZ, RB, JJS, VBP 등으로 구성된 상대적으로 생소한 조합들의 비율이 높았다.

4.1 학습 시뮬레이션




Fig. 5. The CCoU of the user4 for each knowledge set types during the learning phase

Fig. 5는 콘텐츠의 대부분을 학습하도록 설정된 사용자 4번의 단계별 학습 시뮬레이션 동안 지식 집합 타입별 350개 에세이에 대한 평균 커버리지를 백분율로 나타낸 그래프이다. 학습 시뮬레이션을 위해 학습자는 학습 콘텐츠별로 50번씩 반복 학습을 진행했으며, 5개 등급의 기초 어휘 목록과 교육부 영어과 교육과정 어휘 목록 1개, 그리고 70개의 에세이에 등장한 콘텐츠로 총 3,800회(76개×50회) 학습을 진행하였다. Type(1)의 경우 250회 시점부터 전체 에세이에 대한 CCoU가 크게

상승하는데, 이는 해당 콘텐츠가 일반적으로 많이 사용하는 기본 어휘를 포함하고 있고, 해당 기간 동안 학습한 어휘의 수 역시 상대적으로 높았기 때문이다. 하지만, 사전 학습 콘텐츠로 선정한 70개 에세이를 기반으로 어휘를 공부하는 동안은 학습이 진행되면서 선형적으로 커버리지가 증가함을 알 수 있다. 이에 비해 문법 패턴은 비교적 초반에 커버리지 증가율이 높았다가 잘 쓰이지 않는 문법 패턴을 발견하는 것에 대해서만 추가적으로 학습이 이루어지면서 증가 속도가 서서히 감소하는 패턴을 보였다. 문법 학습은 기본 어휘 학습 시뮬레이션이 끝난 300회 시점부터 시작되며, 품사의 포함 여부만을 파악하는 Type(1)의 경우는 학습한 품사가 380회 시점에 이미 전체 350개 에세이에 등장하는 품사의 80%를 넘기게 된다. 하지만, 어휘는 전체 에세이에 등장하는 어휘의 56.8%에 그치게 되어, 3-gram 품사 시퀀스와 마찬가지로 숙련도에 상대적으로 큰 영향을 주었다.

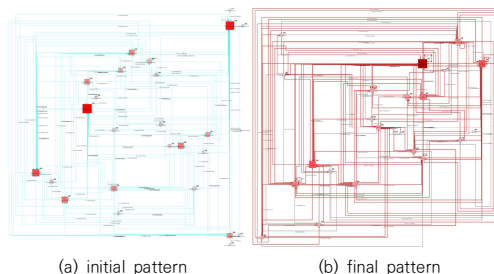


Fig. 6. The initial and final patterns of the filtered PoS during the simulation

Fig. 6은 학습자 객체가 시뮬레이션 과정에 학습하는 초반과 후반의 문법 패턴 그래프로, 어휘, 어간 집합과 품사 시퀀스 정보 및 빈도를 포함하여 분석기에서 관리하는 자료이다. 초반에는 아직 마스터하지 못한 파란색의 얇고 많은 에지들이 분포하지만 후반부에는 학습이 완료되어 상대적으로 굵고 붉은색의 에지를 많이 가지게 된다. 실제로는 훨씬 더 많은 에지와 노드를 지식 집합으로 보유하고 있으나 비슷한 수준의 노드와 에지를 시각화하기 위해 필터링한 결과이다.

4.2 사전 학습 데이터에 대한 숙련도 분석

Table 3은 사전 학습한 70개 에세이에 대한 CCoU와 PP값에 대한 학습자들의 평균, 최대, 최소값을 나타낸 자료로 만점을 받은 셀은 회색 음영 처리하였다.

Table 3. The CCoU and PP values of the users for pre-learned 70 essays

		user1	user2	user3	user4
Type(1)	avg.	0.879	0.898	0.996	1.000
	max.	1.000	1.000	1.000	1.000
	min.	0.788	0.816	0.984	1.000
Type(2)	avg.	0.999	1.000	1.000	1.000
	max.	1.000	1.000	1.000	1.000
	min.	0.967	1.000	1.000	1.000
Type(3)	avg.	0.985	0.988	0.999	1.000
	max.	1.000	1.000	1.000	1.000
	min.	0.907	0.921	0.994	1.000
Type(4)	avg.	0.913	0.924	0.997	1.000
	max.	1.000	1.000	1.000	1.000
	min.	0.788	0.798	0.982	1.000
PP	avg.	0.915	0.928	0.997	1.000
	max.	1.000	1.000	1.000	1.000
	min.	0.825	0.846	0.988	1.000

Fig. 7은 기초 어휘와 70개 사전 학습 콘텐츠를 학습한 4개 사용자 객체별로 사전 학습한 70개 콘텐츠에 대한 숙련도 점수와 평균 수치를 4명의 평균 숙련도를 기준으로 정렬하여 시각화한 자료이다.




Fig. 7. Proficiency Points of the users for the pre-learned 70 contents

시뮬레이션 설정으로부터 학습자의 번호가 높아질수록 높은 학습률과 낮은 학습 완료 임계값을 가지기 때문에 학습 시뮬레이션 결과 user4의 숙련도 점수는 모두 만점에 해당하여 관련 어휘나 문법 시퀀스를 빠짐없이 마스터 하였으며, 반대로 user1은 마스터한 콘텐츠도 있으나, 0.825를 최소값으로 가지고 어휘에 해당하는 Type(1)과 3-gram 품사 시퀀스 패턴인 Type(4)에서 0.788로 낮은 점수를 받았다. 학습 시뮬레이션 과정에서 파라미터 설정을 제외한 나머지 조건인 학습 콘텐츠와 반복 학습 횟수는 동일했다.

실험 결과에서 학습자 전원이 숙련도 만점을 받은 콘텐츠는 10번, 55번, 240번 에세이로 기본 어휘나 자주 쓰이는 문법 위주로 구성되어 있고 분류만 'America &

patriotism', 'citizenship', 'patriotism'으로 달리하여 중복 등록된 'Life, Liberty, and the Pursuit of Happiness'라는 제목의 에세이였다. 가장 낮은 숙련도 평균 점수를 받은 에세이는 'sports' 분류에 속한 'Ath(l)eticism' 이라는 제목의 325번 에세이였는데, 'hebrew', 'cutthroat', 'lox', 'yiddish', 'vernacular', 'dreidel', 'tulsa', 'yasser', 'proselytizing', 'emanate', 'chutzpah', 'shlal' 등 다른 콘텐츠에는 등장하지 않고 생소한 어휘들의 비중이 높은 편이었고, 에세이 길이, 문장의 개수, 단어의 개수도 10번 에세이에 비해 325번 에세이가 더 높았다. 품사 시퀀스 그래프를 구성했을 때 노드의 크기는 10번 에세이가 28, 325번 에세이가 29로 큰 차이는 없었지만, 에지의 개수가 각각 152개, 215개로 큰 차이가 나서, 문법적 구성에서의 복잡도 또한 325번 에세이가 높았음을 확인하였다.

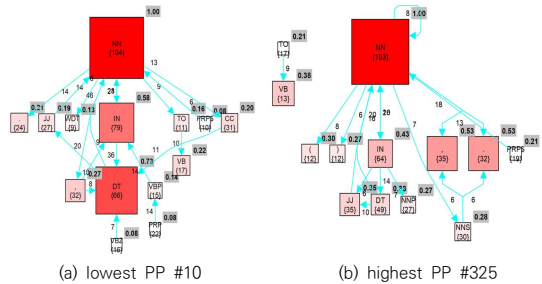


Fig. 8. PoS pattern graphs of essay #10 and #325 (filtering condition: node/edge count)5

각각의 콘텐츠로부터 노드와 에지의 필터링 조건을 5 이상으로 하여 반복되는 패턴을 추출하여 구성한 품사 시퀀스 그래프의 경우 Fig. 8과 같이 유사한 패턴이 발견되었으며 오히려 10번 에세이의 노드, 에지의 개수가 14, 19로 325번 에세이의 13, 18에 비해 높아 숙련도 점수가 높았던 10번 에세이의 경우 생소한 표현 보다는 반복되거나 공통적으로 나타나는 문법적 구조를 많이 활용하고 있음을 알 수 있었다.

4.3 숙련도 예측 및 검증

학습하지 않은 280개 나머지 콘텐츠에 대한 숙련도를 예측하고, 맞춤형 교육 지원에 대한 검증을 위해 해당 콘텐츠를 분석하였다.




Fig. 9. Predicted Proficiency Points of the users for the 280 evaluation contents

Fig. 9는 사전 학습을 완료한 학습자들에 대해 학습 경험이 없는 280개 에세이 각각에 대해 개별적으로 예측한 숙련도 점수를 4명의 평균값으로 정렬하여 나타낸 자료이다. 미학습 콘텐츠라는 점에서 사전 학습한 70개 콘텐츠에 비해 상대적으로 낮은 점수를 보임에도 불구하고 사전 학습 패턴이 반영된 패턴을 나타내었다. 특히, user1,2의 경우는 대부분의 콘텐츠에 대해 평균 이상의 숙련도를 보였고, user3,4는 낮은 숙련도 점수를 보였다. 다만, user1,2의 숙련도는 user3,4에 비해 학습된 콘텐츠일 때의 숙련도에 비해 상대적으로 크게 하락하였는데 이는 기존의 높은 숙련도를 얻기 위해 에세이별로 특화된 흔치 않은 어휘나 문법 패턴의 비중이 높았기 때문이다. 이에 비해 user3,4가 학습한 보편적인 어휘나 문법 패턴은 새로운 콘텐츠에서도 비교적 안정적인 비중으로 포함되어 있기 때문에, 하락의 폭이 상대적으로 낮음을 확인하였다.

학습자 객체들은 동일한 기본 어휘와 문법 지식을 학습하였으나, user3,4는 학습 내용을 거의 마스터하였고 user1,2는 상대적으로 마스터하지 못한 지식 요소들이 많은 상황 설정으로 시뮬레이션하였다. Fig. 10은 사전 학습된 콘텐츠와 검증을 위한 콘텐츠에 대한 학습자들의 지식 집합 타입별 숙련도 평균값을 보여주는 레이더 차트이다. 차트로부터 user 1, 2의 결과와 user 3, 4의 결과가 각각 유사함을 알 수 있다. (a)는 사전 학습한 콘텐츠에 대한 숙련도 점수이므로 비교적 높은 숙련도 패턴이 이를 잘 반영해주고 있다. 하지만, (b)는 미학습 콘텐츠에 대한 숙련도 예측 점수들에 대한 평균값을 보여준다. 대체적으로 품사 종류 및 품사의 2-gram 패턴은 학습자 모두가 공통적으로 자주 접하면서 익숙해진 부분이다.




Fig. 10. Average CCoU of the users for the contents

실제로 2-gram을 기초 단위로 해서 3-gram 이상의 패턴이 구성되기 때문에 기초적인 패턴 구조에 대해서는 70개의 콘텐츠의 지식 집합만으로도 높은 커버리지를 얻을 수 있다. 하지만, 어휘의 경우는 학습자 객체들 모두 사전에 미학습한 어휘들이 포함될 수밖에 없으므로 인해 숙련도 평균의 패턴은 사전 학습 콘텐츠와 유사하나 전반적으로 점수가 낮다. 그 차이에 해당하는 지식 집합의 크기만큼 새로운 콘텐츠 학습을 위해 추가적으로 학습이 필요한 부분이므로, Analyzer의 `make_words_to_learn()`, `make_PoS_patterns_to_learn()`을 통해 학습이 필요한 어휘와 문법 패턴을 생성하여 각 학습자에게 맞춤형 교육자료를 제공할 수 있다.

Table 4. The count of the words to learn

user# \ content#	1	2	3	4	avg. PP
136	0	0	0	0	1.00
51	50	44	1	0	0.93
28	33	31	23	21	0.89
72	108	103	61	64	0.71

Table 4는 미학습 콘텐츠를 완전히 학습하기 위해 필요한 학습자별 어휘량을 보여준다. 136번 콘텐츠의 경우는 학습된 콘텐츠의 동일한 콘텐츠가 검증용 콘텐츠에 분류만 달리하여 중복되어 있는 경우였기 때문에, 4명의 숙련도가 모두 1이 나온 경우였다. 이 외에 추가로 숙련도 평균이 상,중,하에 해당하는 사례를 찾아 정리하였다. user3의 경우 51번 콘텐츠에서 미학습된 1개의 어간은 'polio'로 전체 콘텐츠에서 5회 등장하는 어휘였으며, 사전 학습 시뮬레이션에서 25번 콘텐츠에 포함되어 있던 어휘였다. user4는 이를 학습 완료했기 때문에, 'polio' 어간을 포함한 51, 124, 137, 174번 미학습 콘텐츠에 대한 숙련도 증가에 영향을 주었다. user4의 경우도 비교적 낮은 숙련도를 보인 72번 콘텐츠의 경우는 'maori', 'neurosi', 'calypso', 'martha', 'carcanet',

‘quantum’, ‘spinal’ 등 흔치 않은 어간들이 많이 포함되어 있는 난이도 높은 콘텐츠였으며, 오히려 user3이 user4보다 ‘aesthet’, ‘arcan’, ‘constitut’ 등의 어간 학습을 마스터하여 더 높은 숙련도 점수를 받은 예외적인 경우였다.

문법 패턴에 대해서도 동일한 분석이 가능하며, 본 연구에서 자동 추천되는 맞춤형 학습 데이터셋을 이용하면 미학습 콘텐츠에 대한 학습 과정에 필요한 맞춤형 어휘나 문법을 쉽게 생성할 수 있다. 또한, 이를 이용할 경우 어휘와 문법 패턴과 관련한 추가 예문을 인터넷이나 기타 콘텐츠에서 검색하여 제공할 수 있기 때문에 맞춤형 교육 지원에 활용이 가능하다.

5. 결론

본 연구에서는 맞춤형 영어 교육을 지원하기 위하여 어휘와 문법을 대상으로 학습지식 데이터를 구축하였고, 학습자의 숙련도를 정의하였다. 학습자의 숙련도는 학습 대상의 난이도나 학습자의 학습 습득력, 망각속도 등을 고려하여 결정된다. 구축된 데이터 분석을 통하여 학습 상황을 정량화하여 수치나 그래프로 제공할 수 있다. 또한 콘텐츠별로 지식요소들의 빈도나 유사도를 보여줄 수 있으며, 숙련도는 어휘나 문법에 대하여 맞춤형으로 학습 콘텐츠를 생성하거나 추천하는데 활용할 수 있다. 이후 시뮬레이션을 통하여 구축한 지식데이터와 정의된 숙련도가 의미있게 적용될 수 있음을 보였다.

단어와 문법 시퀀스에 대한 평소 추적 방안만 마련된다면, 학습자별로 적절한 난이도의 콘텐츠를 추천하거나 어휘 또는 문법에 관련한 문장 등을 사전에 추출하여 학습자별로 맞춘 개별 학습 콘텐츠를 구성하는데 도움을 줄 수 있는 맞춤형 교육 지원 도구로 활용이 가능할 것으로 보인다.

향후 연구에서 본 연구에서 제안한 맞춤형 영어 교육 지원 도구를 기반으로 추가 데이터를 확보하고, 실제 현장에서 학습자들을 대상으로 기초 콘텐츠로부터 숙련된 어휘나 문법 패턴에 대한 누적 정보를 쌓아 분석할 수 있다면 보다 효과적인 검증이 가능할 것으로 보인다. 또한, 파라미터 차원을 높인 후 통계적 기법과 더불어 머신러닝 알고리즘을 활용한 분석 결과와 비교해보는 연구도 효과성을 높이는 데 기여할 것으로 보인다.

REFERENCES

- [1] K. Noh, S. Ju & J. Jung. (2011). An Exploratory Study on Concept and Realization Conditions of Smart Learning. *Journal of Digital Convergence*, 9(2), 79-88.
DOI : 10.7236/JIIBC.2016.16.1.21
- [2] W. Jung. (2020). A Design for the Personalized Difficulty Level Metric based on Learning State. *Journal of the Korea Convergence Society*, 11(3), 67-75.
DOI : 10.15207/ JKCS.2020.11.3.067
- [3] S. M. nafea, F. Siewe & Y. He. (2018). ULEARN: Personalized Course Learning Objects Based on Hybrid Recommendation Approach. *International Journal of Information and Education Technology*, 8(12).
DOI : 10.18178/ijiet.2018.8.12.1151
- [4] W. Jung & E. Lee (2021). Analysis Techniques to Support Personalized Music Education Based on Learner and Chord Data. *Journal of the Korea Convergence Society*, 12(2), 51-60.
DOI : 10.15207/JKCS.2021.12.2.051
- [5] H. Kim. (2017). A Comparative Study of English Vocabulary Learning between Mobile Application and Vocabulary List. *STEM Journal*, 18(1), 183-206.
DOI : 10.16875/stem.2017.18.1.183
- [6] H. Kim. (2019). Cutomized Mobile Application Based on Learners' Different Levels in the EFL Classroom: Efficiency and Value of Apps. *LAK Journal*. 27(1). 42-62.
DOI : 10.24303/lakdoi.2019.27.1.42
- [7] M. Okhdar & A. Ghaffari (2018). English Vocabulary Learning through Recommender System based on Sentence Complexity and Vocabulary Difficulty. *Kyberbetes*, 47(1), 44-57.
DOI : 10.1108/K-06-2017-0198
- [8] C. Chen & Y. Li (2010). Personalised context-aware ubiquitous learning system for supporting effective English vocabulary learning. *Interactive Learning Environments*, 18(4), 341-364.
DOI : 10.1080/10494820802602329
- [9] C. Chen, L. Chen & S. Yang (2018). An English Vocabulary Learning App with Self-regulated Learning Mechanism to Improve Learning Performance and Motivation. *Computer Assisted Language Learning*, 32(3), 1-24.
DOI : 10.1080/09588221.2018.1485708

[10] L. Fang, L. Tuan, S. Hui & L. Wu. (2017). Personalized Question Recommendation for English Grammar. *Expert Systems*, 35(2). DOI : 10.1111/exsy.12244

[11] X. Wang, J. Chen & T. Zhang. (2021). Facilitating English Grammar Learning by a Personalized Mobile-Assisted System With a Self-Regulated Learning Mechanism. *Frontiers in Psychology*, 12(10). DOI : 10.3389/fpsyg.2021.624430

[12] K. Kim & H. Shin. (2016). Student-oriented Multi-dimensional Analysis System using Educational Profiling. *Journal of Digital Convergence*, 14(6). 263-270. DOI : 10.14400/JDC.2016.14.6.263

[13] R. Felder & L. Silverman. (1988). Learning and Teaching Styles in Engineering Education. *Engineering Education*, 78(7), 674-681. DOI : 10.1109/FIE.2008.4720326

[14] D. Silva & F. Dora. (2014). An Automatic Approach for Customization of Teaching Process based on Learning Styles in Adaptive and Intelligent Learning Systems. *Brazilian Journal of Computers in Education*, 22(2), 1. DOI : 10.5753/RBIE.2014.22.02.1

[15] *The Basic Spelling Vocabulary List*. (2022, Jan 1). <https://www.readingrockets.org/article/basic-spelling-vocabulary-list>

[16] *Penn Part of Speech Tags*. (2022, Jan 1). <https://cs.nyu.edu/~grishman/jet/guide/PennPOS.html>

[17] Ministry of Education. (2015). *2015 Revised National English Curriculum* : Ministry of Education.

정 우 성(Jung Woosung)

[종신회원]



- 2003년 2월 : 서울대학교 컴퓨터공학과(공학사)
- 2011년 8월 : 서울대학교 컴퓨터공학과(공학박사)
- 1998년 9월 ~ 2002년 2월 : SK 유비케어 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

이 은 주(Eunjoo Lee)

[정회원]



- 1997년 2월 : 서울대학교 계산통계학과(이학사)
- 1999년 2월 : 서울대학교 전산과학과(이학석사)
- 2005년 2월 : 서울대학교 전기컴퓨터공학부(공학박사)

- 2005년 3월 ~ 2005년 10월 : 서울대학교 공과대학 BK 박사후 연구원
- 2005년 11월 ~ 2006년 2월 : 삼성종합기술원 전문연구원
- 2006년 3월 ~ 현재 : 경북대학교 IT대학 컴퓨터학부 교수
- 관심분야: Mining software repository, Software metric, Software evolution, SW education
- E-Mail : ejlee@knu.ac.kr