

일반대학에서 교양 e-러닝 강좌의 중도탈락 예측모형 개발과 조기 판별 가능성 탐색

유지원[†]

요 약

e-러닝 환경에서는 학습자의 학습행동이 학습관리시스템(LMS)에 자동으로 기록되며, 최근에는 이러한 데이터를 분석하여 수업과 학습성과 향상에 활용하는 학습분석학(learning analytics)적 접근이 증가하고 있다. 중도탈락은 e-러닝에서 지속되어 온 문제로, 본 연구는 일반대학 e-러닝 강좌에서 LMS에 기록된 데이터로부터 중도탈락 예측 모형을 구축하여 e-러닝 중도탈락 처방에 기초 자료를 제공하고자 하였다. 국내 일반대학에서 운영되는 교양 e-러닝 강좌를 편의표집하고, 이 강좌를 수강하는 578명의 자료로 중도탈락을 예측하는 로지스틱 회귀분석을 실시한 결과, 주차별로 계획된 학습을 규칙적으로 완료하는 출석과 총 학습시간이 중도탈락 예측에 유의한 선행요인으로 분석되었고, 이 로지스틱 회귀모형은 전체적으로 96%의 정확도로 수강완료자와 중도탈락자를 구분하였다. 또한 학습자가 중도탈락을 결정하기 이전 시점에서 이 모형을 적용하여 중도탈락 조기 판별 가능성을 탐색하고, 본 연구결과를 토대로 시사점과 이 모형의 잠재적 활용가치를 논의하였다.

주제어 : 중도탈락, LMS 로그 데이터 분석, 학습분석학, 조기 판별

Dropout Prediction Modeling and Investigating the Feasibility of Early Detection in e-Learning Courses

Ji Won You[†]

ABSTRACT

Since students' behaviors during e-learning are automatically stored in LMS(Learning Management System), the LMS log data convey the valuable information of students' engagement. The purpose of this study is to develop a prediction model of e-learning course dropout by utilizing LMS log data. Log data of 578 college students who registered e-learning courses in a traditional university were used for the logistic regression analysis. The results showed that attendance and study time were significant to predict dropout, and the model classified between dropouts and completers of e-learning courses with 96% accuracy. Furthermore, the feasibility of early detection of dropouts by utilizing the model were discussed.

Keywords : Dropout, LMS Log Data Analysis, Learning Analytics, Early Detection

[†] 정 회 원: 이화여자대학교 교육공학과 연구교수
논문접수: 2013년 09월 26일, 심사완료: 2013년 11월 20일, 게재확정: 2013년 12월 24일

1. 서론

국내 고등교육에서 e-러닝의 대표적 예는 2001년 이후부터 운영되는 사이버대학을 들 수 있다. 2012년 말 기준으로 국내에는 21개의 사이버 및 원격대학이 운영되고 있으며 11만 명 이상의 학생이 등록한 것으로 집계된다[1]. 사이버대학의 운영부실이나 강의콘텐츠 질 및 최신성 문제 등이 지적되기도 했지만[2], 사이버대학은 많은 연구와 투자를 바탕으로 성장하고 있다. 한편, 최근에는 다수 일반대학에서도 e-러닝 강좌를 도입하여 정규과목으로 운영하고 있는데 4천 4백 개 이상의 e-러닝 강좌가 일반대학에 개설된 것으로 조사되었다[3]. 일반대학에서의 e-러닝 도입은 e-러닝 수업이 가지는 편리성을 비롯한 장점 때문이기도 하지만, 일부 대학의 경우 e-러닝이 재정과 학교 공간 부족과 같은 현실적인 교육인프라 부족 문제를 극복하는데 도움이 되기 때문이라고 보고하고 있다[4][5].

한편 사이버대학과 달리, 유홍준과 정태인(2012)은 일반대학에 개설된 e-러닝 강좌 운영에 대해서는 심층적인 조사와 연구가 전혀 이루어지지 않고 있다고 지적하면서, 국내 일반대학에서 교양기초로 운영되는 e-러닝 강좌 활용 실태 조사연구를 수행하였다. 그 결과, 조사에 응답한 55개의 대학 중 교양기초강좌를 e-러닝으로 운영하는 학교가 0~10%로 나타났고, 학교별로 e-러닝 강좌 개설비율에 현저한 차이를 보였다. 강좌별 수강생도 최저 6명에서 최고 2,340명에 이르기까지 다양하게 조사되었는데, 일반적으로 수강생은 평균 100명 이상으로 나타났고, 200~300명 단위의 대형 강의로 운영하는 학교들도 다수 조사되었다. 그러나 Macfadyen과 Dawson(2010)은 학생 규모가 큰 강의의 경우, 교수자가 학습자의 학습 상태를 파악하기 쉽지 않아 효율적인 수업 운영에 어려움을 겪게 된다고 지적한 바 있다. 나아가 그들은 학생들의 학습상태를 빠르게 파악할 수 있는 새로운 도구와 전략이 필요하다고 강조하면서, 특히 학습에 위기를 맞은 학생들을 조기에 선별함으로써 이들을 지원할 수 있는 방안을 마련해야 한다고 주장하였다.

최근에 이러한 요구에 대안으로 e-러닝 학습자

의 행동데이터를 분석하여 교육운영 및 성과 개선에 활용하는 사례와 연구가 활성화되고 있다. 이러한 접근을 학습분석학(learning analytics)이라고 하는데, 학습분석학이란 교육적 데이터마이닝으로 방대한 데이터로부터 유용한 정보 또는 패턴을 추출하고, 이 결과를 교수-학습 상황에 적용하여 학습성과를 향상시키고자 하는 접근을 일컫는다[6][7]. 이는 학습자가 학습관리시스템(Learning Management System, 이하 LMS)을 통하여 학습콘텐츠를 학습하고 학습활동을 수행하면서 이러한 행동이 LMS에 자동으로 기록되고, 기록된 로그 데이터(log data)로부터 학습자의 실제 학습행동을 파악할 수 있다는 점에서 비롯된다. 예로 학습자의 강의실 접속 시간, 질문 횟수, 접속 횟수, 게시글 작성 횟수 등이 자동으로 기록되며, 이러한 로그 데이터는 학습자의 학습참여 정도를 대리하는 중요한 정보를 제공한다. Wang과 Newlin(2002)은 블랙보드(Blackboard®)와 같은 LMS에 저장된 학습자의 로그 데이터를 분석함으로써 학습성과를 조기에 감지할 수 있다고 논의하였다. Campbell, DeBlois와 Oblinger(2007)도 교육기관의 LMS에 누적되는 데이터를 학습분석학적 접근으로 분석하여 학습에 실패할 가능성이 높은 학습자를 선별하고 지원할 수 있다고 주장하였다. 이러한 연구와 논의는 누적되는 e-러닝 학습자의 로그 데이터 분석을 바탕으로 수업현장에 적절한 처방을 가함으로써 학습성과 향상에 기여할 수 있음을 시사한다.

하지만 e-러닝 학습자의 방대한 정보가 기록되어도 대부분의 LMS에서는 유의미한 요소를 선별적으로 추출하여 제시하거나, 학습성과 예측 모델에 따라 데이터를 조합하고 의미화하여 제공하지 않기 때문에 교수자가 로그 데이터를 교수-학습 현장에서 직접 활용하기 어려운 실정이다[10][11]. 또한 교수자에게 학습자들의 주요 학습패턴이나 위험도를 인식할 수 있는 정보를 제공하기 위해서는 학습자의 어떤 행동데이터가 학습참여와 학업성과에 유의미한지를 실증적으로 규명하는 연구가 선행되어야 한다. 이러한 연구를 토대로 학습성과나 위험을 예측할 수 있는 모델이 개발되어 활용된다면, 교수자는 제공되는 정보로 학습자의 학습과정을 실시간으로 모니터링함으로써 신

속하게 수업개선 방안을 모색하고 적용함으로써 교수-학습에서 처방적 효과를 기대할 수 있다.

한편, e-러닝에서 발생하는 위기의 대표적 예는 중도탈락이다. 중도탈락은 학습성과의 중요한 지표로 간주되며, 특히 e-러닝 학습상황에서의 중도탈락은 오프라인대학에 비해 높은 것으로 알려져 [12][13] e-러닝에서 중요하게 다루어져 왔다. 대부분 e-러닝에서 중도탈락 연구는 사이버대학의 학습자를 대상으로 중도탈락 관련 요인을 규명하는 연구가 주를 이루었으며, 일반대학에서 운영되는 e-러닝 강좌에 대한 중도탈락 연구는 찾아보기 어렵다. 그러나 김현숙과 박은영(2011)은 동일한 e-러닝 강좌를 수강하는 사이버대학생과 일반대학생을 비교하는 연구를 통해 두 집단의 학생들이 수업에서 보이는 태도와 수업참여 양상, 강의 만족도에 대한 지각이 현저히 다르다고 논의한 바 있고, 심미자와 심영남(2010)도 사이버대학생과 일반대학생의 상호작용 양상을 비교하여 이들이 동일하지 않음을 논의하였다. 이러한 논의는 일반대학의 학습자를 대상으로 한 e-러닝 중도탈락 연구가 필요함을 시사한다.

따라서 본 연구는 두 가지의 목적을 가지고 수행되었다. 첫째, 일반대학에서 운영되는 e-러닝 교양강좌에서 수강생들의 중도탈락을 예측할 수 있는 모형을 개발하고자 한다. 기존 중도탈락 연구에서는 주로 학습자의 배경 요인들과 중도탈락 간의 관계를 검토하였으나, 본 연구에서는 학습자의 학습행동을 객관적으로 대리하는 LMS에 기록된 로그 데이터를 활용하여 중도탈락 예측에 유의한 요소를 검증하고 모형을 개발하고자 한다. 둘째, 개발한 중도탈락 예측 모형을 활용하여 조기에 중도탈락자 예측에 어느 정도 유의한지 그 활용가능성을 탐색하고자 한다. 이에 본 연구는 일반대학에서 e-러닝 강좌 운영 개선안 모색에 기초자료를 제공할 것으로 기대한다.

2. 이론적 배경

2.1 중도탈락(Dropout)

중도탈락이란 일반적으로 교육을 목적으로 등록한 소정의 과정을 공식적으로 철회하여 과정을

완료하지 못하는 학습자를 일컫는다[12][16]. 중도탈락은 실제 연구에서는 다양하게 정의되어 사용되는데, 자퇴와 제적을 의미하기도 하고[12], 수강신청한 과목을 공식적으로 철회하거나 해당 학기에 과목을 이수하지 못하는 경우를 뜻하기도 하며[16][17], 성취도가 70점 이하 또는 학점이 D, F에 해당하는 학습자를 잠재적 중도탈락자로 분류하기도 한다[18][19]. 본 연구에서 중도탈락은 등록한 과목을 공식적으로 철회하여 과목 수강을 포기한 것으로 정의하였다.

국내 중도탈락 연구는 주로 사이버대학과 기업의 e-러닝 수강생을 대상으로 수행되었고 [12][18][20][21][22], 학습자의 배경 변인, 학습자 내적 특성 변인, 교육과정 및 내용 변인, 교육환경 변인 등을 중심으로 중도탈락에 영향을 미치는 요인을 파악하는데 초점을 두고 있다. 주영주, 장미진과 이현주(2007)는 사이버대학에서 11명의 실제 중도탈락자와의 면담조사를 실시한 결과, 일과 학업 병행의 어려움, 개인적 사정, 목표에 대한 변경, 행정적인 지원 부족, 학업결과에 대한 회의, 낮은 학점을 중도탈락 결정에 주된 요인으로 도출하였다. 임연옥(2007)은 표집한 사이버대학에서 9학기동안 자퇴와 제적된 2000여명의 중도탈락자 중 설문에 응답한 348명의 자료로 학습자 관련 변인과 중도탈락 간의 관계를 규명하였다. 연구결과, 학습시간 부족과 재정적인 문제가 중도탈락 결정에 가장 큰 원인으로 파악되었으며, 온라인 교육환경의 부적응과 사이버대학에 대한 낮은 인지도도 원인으로 분석되었다. 또한 저자는 이수율과 중도탈락 간에 높은 상관관계를 밝히고 학점 포기가 잦을수록 중도탈락으로 이어질 확률이 높아질 수 있다고 해석하였다. Lee, Choi와 Kim(2013)은 국내 사이버대학생을 대상으로 수강완료자와 중도탈락자를 구분할 수 있는 결정요인을 검증한 결과, 중도탈락자보다 수강완료자들이 초인지적 자기조절학습 기술과 학업적 통제소재를 높게 지각한다고 밝히고, 이들 요인이 학습지속성 결정에 중요한 영향을 미친다고 논의하였다.

한편, Willging과 Johnson(2009)은 미국의 온라인석사학위 프로그램에 등록된 83명의 학생들을 대상으로 학습자 배경 변인의 중도탈락 예측력을 검증하였다. 연구참여자 중 27명이 3년 과정을 완

료하지 못한 것으로 나타나 33.7%의 중도탈락률을 기록하였고, 로지스틱 회귀분석을 수행한 결과, 성별, 나이, 학점, 인종, 지역, 직업 등의 배경변인은 중도탈락 예측에 유의하지 않은 것으로 나타났다. 이러한 선행연구를 종합해 보면, 통제소재 변인, 자기조절학습 기술, 재정적 지원이 중도탈락자 결정과 예측에 유의한 변수로 분석되었고 학습자 배경 요인이 중도탈락에 미치는 영향은 일관되지 않거나 미미하였다. 특히 사이버대학과 상황이 다른 일반대학 학습자에게는 배경 요인보다 학습 관련 변인이 더 중요할 것으로 예측되고, 교수-학습상황에서 중도탈락에 대한 처방을 모색하기 위해서도 학습과정에서 나타나는 학습자 특성을 중심으로 중도탈락 관련 요인들을 규명할 필요가 있다고 사료된다.

2.2 LMS 로그 데이터 분석과 학습분석학

앞에서 살펴본 중도탈락 선행연구에서도 나타났듯이[12][21][24], 중도탈락 연구의 대표적 어려움은 자료수집이다. 실제 중도탈락자로부터의 자료수집이 쉽지 않기 때문에, 연구대상자가 낮은 참여도를 보이거나 작은 수의 표본으로 연구가 수행된다. 그런데 e-러닝 학습환경에서는 학습자의 학습활동이 LMS에 자동으로 수집됨으로써 별도의 자료수집 없이도 학습자 행동을 분석하는데 매우 가치 있는 정보를 얻을 수 있다[10][25][26]. 특히 LMS 상에 수집되는 로그 데이터는 웹 서버 로그 데이터에 비해 학습자의 게시판 활동, 퀴즈 및 시험 성취도, 과제 활동 등 상대적으로 높은 수준의 데이터를 제공한다는 장점이 있다[27]. 따라서 학습자가 e-러닝 학습과정에 어떻게 참여하는지 학습활동에 대한 LMS 로그 데이터를 활용한다면 학습행동에 대한 신뢰할 수 있는 자료를 직접 수집·분석함으로써 중도탈락자들에 대한 이해를 심화할 수 있다.

또한 최근에는 해외 저명 대학에서 개설한 MOOC(Massive Open Online Courses)와 같은 대규모 공개 온라인 강좌가 확대되면서, 교수자, 학습자, 학습콘텐츠 간의 상호작용으로 발생하는 방대한 양의 데이터를 분석하여 활용하는데 관심이 커지고 있다. 수집된 거대한 데이터 집합으로

부터 잠재적으로 유용한 정보를 추출하는 것을 교육적 데이터마이닝(data-mining)이라고 하며, 데이터 마이닝 결과는 교육기관의 운영과 정책 결정에 활용된다. 학습분석학은 이와 유사하지만, 한 걸음 더 나아가 교육적 데이터마이닝 결과를 토대로 교수-학습적 처방을 제공하여 수업 개선과 학습성과 향상을 도모한다는 점에서 차이가 있다[6][28]. 따라서 학습분석학의 주요한 기능은 학생들의 학습과정을 모니터링하고 예측하며, 학습에 어려움을 겪는 학습자를 미리 감지함으로써 이들에 대한 적절한 처방을 제시하는 기능이다[29]. 미국 교육부에서 발간한 2012년 보고서에 따르면[28], 학습분석학을 통해 개발된 모델은 다음과 같이 활용할 수 있다고 설명한다. 학생들이 다음 학습 주제를 학습할 준비가 되었는지, 추가적인 연습이 필요한지, 학습자가 수강을 완료하지 못하고 중도탈락할 위험은 없는지, 처방이 제공되지 않을 경우 학생의 예측되는 성적은 어느 정도인지, 다음 수강에 적합한 과목은 무엇인지, 학생에게 상담을 제공해야 할지 등의 질문에 대한 정보를 확보할 수 있다고 한다.

학습분석학적 접근의 대표적 예로 미국의 퍼듀 대학교(Purdue University)의 Course Signal을 들 수 있다. Course Signal은 과목 수강생들의 다양한 개인 정보와 학습활동 정보를 토대로 현재 수강 과목에서의 수행에 대한 피드백을 신호등 색깔로 시각화하여 제공하는 서비스이다. Course Signal은 학습의 위기 수준을 미리 알림으로써 중도탈락률을 줄이고 과목을 성공적으로 수강할 수 있도록 안내하는 효과가 있다고 보고된다[30]. 또한 아리조나(Arizona) 주 소재 Rio Salado Community College의 경우, 41,000명 이상의 학생이 온라인으로 등록되어 있는 학교로 학생들의 학습과정을 자동으로 추적하는 Progress and Course Engagement(PACE) 시스템을 개발하여 도움이 필요한 학생들에게 처방을 제공하고 있다. 이 시스템은 학습자들의 학습사이트에 접속하는 빈도, 학습 자료를 읽는지 또는 제공된 연습을 수행하는지 등의 학습참여도, 과제점수를 성취 예측에 핵심 요인으로 다루고 있으며, 교수자는 이 시스템을 통해 실시간으로 학습자의 학습참여 양상을 확인하고 학습에 어려움을 겪는 학생을 파악

하는데 활용한다[31]. 살펴본 바와 같이, 학습분석학은 방대한 자료에서 정보를 추출하여 모델링하는 차원을 넘어서 예측모형을 교수학습 상황에 적용하여 성과 향상을 추구한다[7][10].

2.3 LMS 로그 데이터 분석에 의한 학업성과 연구

아직까지 학습분석학 연구는 초기 단계로 관련 연구가 많지 않지만, 유사한 원리를 바탕으로 하는 LMS 로그 데이터 분석 연구를 살펴보면 그 잠재성을 확인할 수 있다. 다수 실증적 연구에서 LMS 로그 데이터로부터 추출된 학습자의 행동지표는 성취와 유의한 관계를 보였고[10][26][32], 이렇게 추출한 변인을 토대로 상정한 학업성취 예측모형은 성취를 설명하는데 상당한 설명력을 보이는 것으로 밝혀졌다[10][26]. 중도탈락 예측에 LMS 로그 데이터를 부분적으로 활용한 전주성(2010)은 307명의 사이버대학생을 대상으로 잠재적 중도탈락자를 예측하는 연구를 수행하였다. 중도탈락의 선행요인으로 LMS의 로그 데이터로부터 학습자의 총 학습시간, 강의 총 접속수를 추출하였고, 설문으로 학습자의 내적특성, 교육지속의향, 교육과정 및 내용에 대한 만족도, 교육환경에 대한 적절성을 비롯하여 교육수준, 주당 근무시간, 성별, 나이와 같은 배경정보를 수집하였다. 학업성취도 70점을 기준으로 과정수료자와 잠재적 중도탈락자로 구분하였으며, 연구대상 중 21.5% 수강자들이 잠재적 중도탈락자로 나타났다. 로지스틱 회귀분석을 실시한 결과, 해당 과목의 잠재적 중도탈락을 예측하는데 총 학습시간, 강의 접속수, 교육과정 및 내용 변인만 유의한 선행요인으로 분석되었다. 이 연구결과는 학습자의 배경요인보다는 학습자가 실제 수강을 위해 보인 행동이 중도탈락을 예측하는데 강력한 결정요인임을 입증할 뿐 아니라, 학습자의 행동을 파악하는데 LMS 로그 데이터가 유용함을 시사하였다.

또한 Morris 외(2005)의 연구에서는 중도탈락자와 성공적 수강완료 학생 간에 학습참여 빈도와 학습시간에 큰 차이를 보였으며, 성공적으로 완료한 학생의 성취도에는 학습콘텐츠에 접속한 빈도, 게시글을 읽은 빈도와 학습시간이 유의한 영향을

미쳤다. 국내 사이버대학 학습자의 웹 로그 데이터로 성취도 예측 연구를 수행한 강민석, 김진일과 박인우(2009)에서는 출석률, 진도율, 누적학습시간, 강의실 접속수, 게시판 게시와 질의응답횟수 등 다양한 학습참여 관련 지표와 성취도 간의 관계를 분석한 결과, 출석률이 학업성취도 예측에 가장 강한 요인으로 분석되었고, 토론게시판에 글 작성 횟수, 강의실 접속 횟수, 진도율, 자료게시판 자료등록 횟수 순으로 영향력을 나타내었다. 반면 누적학습시간과 Q & A 게시판 질의응답횟수는 통계적으로 유의하지 않았다. 이 결과는 꾸준한 출석과 토론게시판의 글 작성과 같이 적극적인 수업참여가 학업성취도와 높은 관련성이 있는 것으로 해석할 수 있다.

이 외에도 e-러닝 수업에서의 규칙적 학습을 논의한 연구들이 있다. Elvers, Polzella와 Graetz(2003)는 로그 분석을 한 결과, e-러닝 수업에서 학생들이 시험 전날과 시험 당일에 사이트 접속이 폭주하는 것으로 나타났다고 보고하면서 e-러닝 학생들의 마감시간에 압박하여 집중적으로 학습하는(cramming) 양상을 보인다고 하였으며, Tuckman(2005)은 e-러닝에서 지연행동을 보이는 학생들이 규칙적으로 학습하는 학습자보다 낮은 성취를 보인다고 논의하였다. 조일현과 김정현(2013)은 학습분석학 접근으로 일반대학 e-러닝 학습자의 LMS 로그 데이터로부터 학업성취 예측모형을 개발하는 연구를 수행하였다. 연구결과, 학습자가 규칙적으로 접속했는지를 의미하는 학습시점 간격의 규칙성이 학업성취를 정적으로 유의하게 예측한 반면, 총 학습시간과 학습 접속 빈도는 성취예측에 유의하지 않았다. 이 결과는 e-러닝에서 정기적으로 학습하는 규칙적 학습의 중요성을 입증한 것으로 해석된다. 또한 저자들은 상정한 예측모형이 16주 수업 중 2/4 시점이 경과하면서 학업성취를 유의하게 예측할 수 있음을 밝히고, 학습분석학 활용 잠재성을 논의하였다.

이상의 연구에서 LMS 로그 데이터에서 추출한 일부 지표는 학업성과 밀접한 관계가 있을 뿐 아니라, 자기보고식 설문에 의존한 기존의 연구에 비해 LMS 로그 데이터를 활용한 연구는 학습자 행동에 대해 보다 정확하고, 객관적이며, 학습자의 추가적인 개입 없이 관련 자료를 수집할 수

있는 장점이 있음을 알 수 있다. 따라서 LMS에서 수집한 데이터는 학습성취와 중도탈락과 같은 학습성과 예측에 직접적이고 중요한 정보로 활용이 가능하며, 본 연구는 중도탈락자들의 실제 학습과정에서 보인 행동데이터를 토대로 중도탈락 예측 모형을 개발하고 이 모형의 잠재적 활용성을 탐색하고자 한다.

3. 연구방법

3.1 연구대상

본 연구는 수도권 소재 4년제 일반대학인 A대학교에서 2012년 학부에 개설된 교양 e-러닝 강좌를 편의표집하여 수행하였다. A대학교는 남녀공학으로 매학기 e-러닝 강좌를 운영하고 있으며, 표집된 강좌의 교과목명은 '나의 삶의 색'으로, 3학점 과목이다. 해당 과목은 1명의 교수자와 2명의 튜터가 2분반을 맡아 수업을 운영하였으며, 초기에 등록된 수강학생은 총 600명이었다. 이 과목은 각 분반에 300명의 학습자로 운영되는 대형강의로, 15주 동안 진행되었다. 수업내용은 색채학에 대한 내용으로 시험을 제외한 모든 수업은 100% 온라인으로 진행되었고, 학생들은 매주 정해진 분량의 강의동영상을 정해진 기간 내에 학습을 완료해야 해당 주차에 출석으로 인정되었다. 평가는 출석(20%), 4번의 과제(20%), 2번의 오프라인에서 치러진 중간고사와 기말고사(60%)로 이루어졌다. 연구대상은 남녀 비율이 유사하고, 4학년이 과반수 이상으로 가장 많았으며, 그 다음으로 3학년, 2학년, 1학년 순으로 나타났다. 학생들의 전공은 건축공학과, 경영학과, 화학과, 의상학과, 영어영문학과, 전자공학과, 법학과, 수학교육학과 등 다양하였고, 응답자의 나이는 평균 24~25세로 파악되었다. 본 연구대상자는 사이버대학이 아닌 일반대학에서 운영하는 이러닝 강좌 수강생이므로 참여자의 배경이 사이버대학 학습자 같이 다양하지는 않다.

3.2 연구도구

본 연구에 활용한 모든 자료는 표집된 e-러닝

강좌에 등록된 수강생의 LMS상에 기록된 로그 데이터를 활용하였다. A대학의 경우, 등록된 과목에 대한 수강절회는 개강 후 4주차 후반에 가능하므로 본 연구에서는 4주 시점까지의 규칙적인 학습을 대리하는 변인으로 출석을 선정하였고, 이와 함께 총 학습시간과 총 접속횟수를 중도탈락의 예측변인으로 선정하였다. 각 변인의 설명은 다음과 같으며 <표 1>에 요약하여 제시하였다.

3.2.1 출석

본 연구에서는 규칙적 학습을 측정하는데 LMS에서 기록된 출석 점수를 활용하였다. 출석의 기준은 주차별로 지정된 학습분량을 지정 기간 내에 모두 수강 완료해야 인정된다. 대부분의 일반대학에서 운영되는 e-러닝 강좌의 경우, 강의계획에 따라 주차별 콘텐츠를 1주 또는 2주 이내에 수강하도록 규칙을 적용하고 있다(예, [35][36]). 본 수업의 경우, 첫 주에만 2주 이내 수업을 출석으로 인정하고, 그 외는 모두 지정 학습내용을 1주 내에 모두 완료해야 해당 주차의 출석으로 인정된다. 본 수업은 중간고사 및 기말고사 기간을 제외하고 총 13주의 강의를 동영상콘텐츠로 제공되었으며, 지정된 기간보다 앞선 강의동영상은 미리 볼 수는 없으나 지나간 수업 내용은 시간과 회수 제한 없이 반복 수강할 수 있다. 따라서 본 연구에서의 출석은 해당 주에 e-러닝 강의실에 최소 1회 접속한 것, 지정된 학습내용 분량을 지정 기간 내에 모두 수강함으로써 일정량의 학습시간과 진도를 충족했음을 나타내며, 규칙적인 학습을 대리하는 지표로 사용하였다. 출석 점수의 산출은 주별로 출석인 경우는 1, 접속해서 학습했으나 진도나 시간이 충분치 못한 경우는 .5, 기간 내 접속하지 않은 결석은 0을 부과하여 4주간 총합으로 계산하였다.

3.2.2 총 학습시간

출석은 지정 기간 내에 정해진 학습내용을 모두 수강해야 인정되는 변인이지만, 지정 기간 이후에도 학습콘텐츠에 접속하여 학습할 수 있다. 지정 기간 이후에 학습하는 경우 출석에는 반영

되지 않으나, 실제 학습자가 해당 콘텐츠를 얼마나 학습했는지를 나타내는 주별 접속시간은 기간에 상관없이 콘텐츠 접속시간을 분 단위로 제공하는 지표이며 이를 학습시간으로 간주하였다. 본 연구에 활용된 강의의 경우, 4주 학습내용을 1회 수강하는데 소요되는 기준학습시간은 230분이었으며, 본 연구에서 총 학습시간은 4주까지 누적된 강의콘텐츠 접속시간으로 산출하였다.

3.2.3 총 접속횟수

총 접속횟수는 4주 동안 학습자가 e-러닝 강의실에 접속한 총 횟수를 일컫는다.

3.2.4 중도탈락

본 연구에서 중도탈락은 표집된 e-러닝 강좌를 등록했던 수강생이 수강철회를 통해 공식적으로 과목수강을 포기한 것을 의미한다. 개강 초기 온라인 출석부 상에는 등록되었다가 이후 수강철회로 출석부에서 제외된 학생으로 수강완료자는 0, 중도탈락자는 1로 코딩하였다.

<표 1> 자료 분석을 위한 변수 요약

변인	설명	코드
중도탈락	수강철회 신청에 의한 중도탈락 여부	0=수강완료, 1=중도탈락
출석	4주 간 규칙적인 학습(정기적 접속과 진도 완료) 정도의 출석점수	0=결석, .5=기준학습량 미달, 1=출석으로 4주간 출석점수 합산
총 학습시간	4주 간 콘텐츠 수강시간	4주 간 누적 콘텐츠 접속시간(분)
총 접속횟수	4주 간 강의실 접속횟수	4주 간 강의실 총 접속빈도

3.3 연구절차 및 자료 분석방법

본 연구는 표집된 e-러닝 강좌에 등록한 600명의 학습활동을 기록한 LMS 로그 데이터를 기반으로 수행되었다. 600명의 자료 중 지나치게 누적 총 학습시간이 많은 이상치 22개의 사례를 제거하여 총 578명의 자료를 분석하였다. 자료는 SPSS 18.0을 사용하여, 변인의 기술통계를 요약하고, 변인 간의 상관을 분석하였다. 본 연구에서 종속변인은 중도탈락으로 수강완료와 중도탈락의

이분반응으로 나타나는 범주형 변인이다. 종속변수가 이분변수일 때는 로지스틱 회귀분석(logistic regression)이 적합한 통계적 분석방법으로, 선정한 독립변인에 의해 종속변인의 집단분류를 얼마만큼 설명하는지를 검증할 때 사용한다[37]. 본 연구에서는 중도탈락자와 수강완료자를 예측하는 로지스틱 회귀모형을 구축하고자 로지스틱 회귀분석을 실시하였다. 가설검증에 사용한 통계적 유의수준은 .05이다.

4. 연구결과

4.1 기술통계 및 상관관계 분석

총 학습시간이 지나치게 큰 사례를 제거한 578명의 자료 중 중도탈락자는 30명(5.2%)이었고, 수강을 끝까지 지속한 수강완료자는 548명(94.8%)이었다. 두 집단에서 4주차까지 보인 출석, 총 학습시간, 총 접속횟수의 기술통계는 다음 <표 2>와 같다.

<표 2> 기술통계 분석결과 (n=578)

	중도탈락자 (n=30)	수강완료자 (n=548)	전체 (n=578)
	평균 (표준편차)	평균 (표준편차)	평균 (표준편차)
출석(회)	1.8 (1.25)	3.73 (.57)	3.63 (.76)
총 학습시간(분)	248.67 (284.02)	781.91 (465.01)	754.23 (427.29)
총 접속횟수(회)	7.73 (9.53)	12.10 (4.14)	46.3 (18.61)

중도탈락자의 경우, 4주 출석 횟수는 평균 1.8회로 나타났다. 총 학습시간 평균은, 4주에 해당하는 기준학습시간이 230분이었는데, 이를 18.67분 초과하는 248.67분($SD = 284.02$)으로 나타났다. 이는 지정된 기간 내에 콘텐츠를 수강하지 못해 결석으로 처리되었으나, 이후에 학생들이 해당 콘텐츠를 수강하여 기준학습시간을 충족한 것으로 해석할 수 있다. 또한 총 접속횟수는 평균 7.73회로 나타나 수강을 완료한 학습자 집단의 평균($M = 12.10$)에 비해 월등히 낮았다. 수강을 완료한 학습자 집단의 출석 평균은 4회 중 3.73($SD = .57$)으로 나타나 높은 출석률을 보였고, 학습내용을 한

변 수강하는데 소요되는 기준시간인 230분을 현저히 초과한 787.10분을 학습한 것으로 나타났다.

변인 간 상관관계를 분석한 <표 3>을 살펴보면 모두 변인 간의 상관이 유의수준 .05에서 유의하게 분석되었다. 중도탈락은 출석($r = -.57$), 총 학습시간($r = -.25$), 총 접속횟수($r = -.21$)와 부적인 상관을 보였다. 예측변인들 간의 상관을 살펴보면, 출석은 총 학습시간과는 .21의 상관을, 총 접속횟수와는 .36의 상관을 보였고, 총 학습시간과 총 접속횟수 간에는 .23의 상관을 나타내었다.

<표 3> 변인 간 상관관계 분석결과($n=578$)

변인	1	2	3	4
1. 출석	1			
2. 총 학습시간	.21**	1		
3. 총 접속횟수	.36**	.23**	1	
4. 중도탈락	-.57**	-.25**	-.21**	1

* $p < .05$, ** $p < .01$

4.2 중도탈락 예측 로지스틱 회귀분석

e-러닝 수강자들의 LMS에 기록된 학습행동 변인들의 중도탈락 예측력을 분석하고자 중도탈락 변인을 종속으로 하고, 4주 시점에서의 출석, 총 학습시간, 총 접속횟수를 독립변인으로 투입하여 로지스틱 회귀분석을 수행하였다. 각 변인의 유의성 검증 결과, <표 4>와 같이 출석(Wald = 23.32, $p < .001$)과 총 학습시간(Wald = 13.09, $p < .001$)이 중도탈락 예측에 유의한 것으로 나타났다. Exp(B)를 살펴보면, 출석은 다른 변수를 상수로 통제했을 때, 1단위 증가 시에 중도탈락 승산(odds)이 $e^{(-1.34)} = .26$ 배 감소하는 것으로 나타났다. 총 학습시간은 다른 독립변인을 상수로 통제할 때, 학습시간이 1단위 증가하면 중도탈락 승산은 $e^{(-.01)} = .99$ 배 감소에 기여하는 것으로 나타났다.

<표 4> 중도탈락 로지스틱 회귀분석 결과($n=578$)

변인	B	SE	Wald(df)	Exp(B)	p
출석	-1.34***	.28	23.32(1)	.26	<.001
총 학습시간	-.01***	.002	13.09(1)	.99	<.001
총 접속횟수	.04	.05	.57(1)	1.04	.45
상수항	3.60***	.82	19.21(1)	36.65	<.001

* $p < .05$, ** $p < .01$, *** $p < .001$

위 분석에서 중도탈락 예측에 유의한 변인만을 투입하여 재분석한 결과, <표 5>와 같이 분석되었다.

<표 5> 중도탈락 로지스틱 회귀분석 결과($n=578$)

변인	B	SE	Wald(df)	Exp(B)	p
출석	-1.28***	.27	23.11(1)	.28	<.001
총 학습시간	-.01***	.002	13.00(1)	1.00	<.001
상수항	3.75	.82	21.15(1)	42.33	<.001

따라서 중도탈락 예측의 최종 로지스틱 모형은 다음과 같이 표현된다.

$$\text{Logit}(\text{중도탈락}) = 3.75 - 1.28(\text{출석}) - .01(\text{총 학습시간})$$

최종 모형의 분류정확도를 살펴본 결과(<표 6> 참조), 수강완료자 분류는 97.4%를, 중도탈락자 분류는 70%의 정확도를 보여 전체적으로 96%의 높은 분류정확도를 보였다. Hosmer과 Lemeshow의 모형적합성 검증 결과, 중도탈락 예측 모형은 수용 가능한 수준으로 나타났으며($\chi^2(8) = 11.18$, $p = .19$), Nagelkerke R^2 는 .58로 분석되었다.

<표 6> 모형검정 및 분류 정확도($n=578$)

관찰값	예측값		
	수강완료	중도탈락	정확도
수강완료	534	14	97.4%
중도탈락	9	21	70.0%
전체			96%
-2LL=112.27			
$\chi^2(2) = 123.65$ ($p < .001$),			
Nagelkerke $R^2 = .58$			

절단값(cutoff value): .2

4.3 중도탈락 조기에측 시점 탐색

본 연구에서는 선정된 중도탈락 예측 모형을 활용하여 조기에 중도탈락 예측이 가능한지를 검증하기 위해 개강 후 2주차와 3주차의 누적 출석 점수와 총 학습시간으로 중도탈락을 예측하는 로지스틱 회귀분석을 실시하였다.

<표 7>의 결과와 같이, 2주차의 출석 점수와 총 학습시간으로 중도탈락자의 50%를 예측하였

고, 3주차 시점에서의 출석과 총 학습시간에 따른 중도탈락 예측 로지스틱 모형은 중도탈락자의 60%를 정확히 분류하였다. 시간이 경과함에 따라 로지스틱 모형의 분류정확도와 설명량은 증가하는 것을 확인할 수 있다.

<표 7> 수업진행 시점에 따른 로지스틱 모형 분류적합도 요약(n=578)

관찰값	2주차 모형 예측값			3주차 모형 예측값			4주차 모형 예측값		
	수강 완료	중도 탈락	정확 도	수강 완료	중도 탈락	정확 도	수강 완료	중도 탈락	정확 도
수강 완료	540	8	98.5%	537	11	98.0%	534	14	97.4%
중도 탈락	15	15	50.0%	12	18	60.0%	9	21	70.0%
전체			96%			96%			96%
	-2LL=150.99			-2LL=146.63			-2LL=112.27		
	$\chi^2(2) = 84.93$ ($p < .001$)			$\chi^2(2) = 89.28$ ($p < .001$)			$\chi^2(2) = 123.65$ ($p < .001$)		
	Nagelkerke R^2 =.41			Nagelkerke R^2 =.43			Nagelkerke R^2 =.58		

절단값(cutoff value): .2

5. 논의 및 결론

본 연구는 일반대학에서 운영되는 교양 e-러닝에서 발생하는 중도탈락을 예측하는 모형을 구축하고 조기에 이 모형을 활용할 수 있는지를 탐색하고자 수행되었다. 자료분석은 수도권의 일반대학에서 운영하는 e-러닝 수강 대학생 578명의 자료로 수행되었다. 중도탈락의 선행변인은 LMS에 자동으로 누적되는 학습자의 학습활동 데이터에서 추출하여 활용하였다. 중도탈락을 예측하는 로지스틱 회귀분석을 실시한 결과, 출석으로 측정된 규칙적 학습과 총 학습시간이 중도탈락 예측에 유의하게 분석되었고 총 접속빈도는 유의하지 않았다. 본 연구결과는 정기적으로 접속하여 정해진 학습량을 학습하는 규칙적인 학습과 추가적으로 학습하는 자율적 학습량이 학습지속과 중도탈락 예방에 매우 중요한 요소임을 확인하였다. 이는 학습성과 측면에서 정기적 학습을 강조한 선행연구와 일치하는 결과이며[6][10][32][38], 성취도와 학습시간 간의 유의한 관계를 논의한 선행연구와도 일맥상통한다[16][18].

또한 중도탈락이 결정되는 4주 시점에서 이 두

변인으로 구축된 로지스틱 회귀모형에 의한 수강 완료자와 중도탈락자의 분류정확도는 수강완료자를 97.4%의 정확도로, 중도탈락자는 70%의 정확도로 분류하여 전체적으로 96%의 높은 분류정확도를 보였다. 중도탈락이 결정되는 4주 이전에 로지스틱 모형의 활용 잠재성을 검증하고자 2주 및 3주 시점에 이 모형의 중도탈락 예측력을 검증한 결과, 2주차에서 중도탈락 분류는 50%, 3주차에서는 60%의 중도탈락 분류정확도를 보였다.

이 연구결과를 통한 시사점은 다음과 같다. 첫째, 중도탈락 예방을 위한 규칙적 학습의 중요성이다. 강의실 접속횟수가 중도탈락 예측에 유의하지 않았던 반면, 정기적인 학습인 출석이 유의한 요인으로 나타난 것은 규칙적인 학습이 단순히 강의실 접속횟수보다 중도탈락 결정에 더 중요한 변인으로 해석할 수 있다. 다수 e-러닝 선행연구에서도 정기적으로 꾸준히 학습하는 행동, 시간관리의 중요성을 논의한 바 있으며[6][39][40], 본 결과는 시간관리와 같은 자기조절학습이 성공적 e-러닝에서 필수적인 요인임을 실증적으로 뒷받침한다고 할 수 있다. 특히 중도탈락은 수업 초반의 출석이 결정적으로 작용하는 만큼, 개강 전 또는 개강과 함께 출석 규정에 대한 명확한 설명을 학습자에게 해 주고, e-러닝 강좌의 성공적인 수강을 위한 안내를 제공하며, SMS 문자 메시지를 등을 활용하여 e-러닝 수강이 낯선 일반대학 학습자들에게 수업 초반에 실수하지 않도록 공지하는 등의 지원을 제공할 필요가 있다. 일반대학에서 운영하는 e-러닝의 경우, 학습자를 위한 별도의 오리엔테이션을 하지 않는 경우가 대부분이며, 학습자들에게 공지글을 올리는 정도로 대신하고 있다. 김현숙과 박은영(2011)에서도 오프라인 대학의 학습자들이 e-러닝을 수강할 때 수업전반에 대한 이해가 낮아 성적을 비롯한 수업 전반에 대한 질문이 사이버대학생보다 상대적으로 많았다고 논의하면서 오프라인대학의 오리엔테이션 부족을 지적한 것도 본 연구결과를 뒷받침한다고 할 수 있다. 따라서 오프라인 대학의 학생들에게 e-러닝 수강은 낯선 환경에서의 학습으로 받아들여질 수 있는 만큼, 보다 적극적인 안내가 필요할 것으로 판단된다.

둘째, 중도탈락 예측에 대한 학습시간의 중요성

이다. 본 연구에서 출석으로 인정된다는 것은 이미 해당 주에서 요구하는 기본 학습량을 충족시킨 것을 의미한다. 본 연구에서 중도탈락자와 수강완료 학습자를 비교했을 때 학습시간에 큰 차이를 보였으며 중도탈락자의 경우에도 평균 학습시간이 기본 학습시간을 초과한 것으로 분석되었다. 그럼에도 불구하고, 본 연구에서 학습시간이 중도탈락 결정에 유의한 것으로 나타난 것은, 추가적으로 학습자가 학습콘텐츠를 학습한 시간이 중도탈락 결정에 중요한 요인으로 해석할 수 있다. 또한 4주 시점에서 중도탈락자와 수강완료자간에 학습시간이 이렇게 차이가 나는 것은 수강을 지속하는 학습자가 학습콘텐츠를 다시 복습하거나 수업을 들으면서 학습노트를 만드는 등 학습에 보다 적극적인 참여를 했을 것으로 추측된다. 따라서 학습자들이 해당 주차의 학습콘텐츠를 수강하는 것 외에도 학습내용의 심층적 이해를 돕는 주차별 질문(weekly questions)이나 토론과 같은 활동을 제시하여 추가적인 학습을 유도하는 것이 중도탈락 방지에 도움이 될 것으로 보인다.

셋째, 본 연구에서는 학습자의 배경정보나 자기보고식 설문이 아니라 학습자가 실제 학습과정에서 보인 행동지표인 LMS상에 수집된 로그 데이터를 활용하여 중도탈락을 규명하고 조기 예측가능성을 탐색하였다는 점에서 그 의의를 찾을 수 있다. 이는 학습자의 행동데이터를 활용하여 학습자의 학습양상을 실시간으로 파악할 수 있어 교수자가 교수-학습과정에서 도움이 필요한 학습자를 판별함으로써 이들에게 필요한 도움을 제공하거나 처치할 수 있는 가능성을 시사한다. 즉, 기존의 중도탈락연구는 수업 종료 이후, 중도탈락자들의 특성을 거꾸로 살펴보는 접근이라면, 본 연구는 추후 이러닝에서 중도탈락 예방에 미리 적용할 수 있도록 시도한 점에서 차별성을 가진다. 본 연구에서 상정된 중도탈락 예측 모형의 조기 분류정확도를 분석한 결과, 중도탈락자를 2주와 3주차에서도 50%, 60%로 분류함으로써 이 모형의 활용 잠재성을 보여주었다. 그런데 앞에서 논의했듯이 현재 대다수 LMS는 수집되는 많은 정보 중 유의한 지표를 선별하여 제시해 주지 않기 때문에, 교수자가 이를 유용하게 활용하려면 학습성공에 유의미한 정보만을 추출해서 시각화

시켜주거나 대쉬보드(dashboard)와 같은 인터페이스로 정보를 제공해 주어야 한다. 따라서 교육기관, LMS 개발 업체, 연구자들은 이러한 기능에 대해 관심을 가지고 학습에 도움을 줄 수 있는 모형개발과 간명한 정보 제공에 관심을 가져야 할 것으로 보인다.

본 연구의 제한점과 후속 연구에 대한 제언은 다음과 같다. 첫째, 본 연구는 일반대학에서 운영되는 교양 e-러닝 강좌를 편의표집하였다. 교양 e-러닝 강좌의 경우 대다수의 일반대학에서 학점교류가 가능하며, 운영기준이 유사하나 대학별로 구체적 기준에 약간씩 차이를 보일 수 있다. 따라서 분석된 연구결과의 일반화를 위해서는 타학교에서 운영되는 e-러닝 강좌를 대상으로 연구결과를 확인할 필요가 있다. 둘째, 본 연구는 학습자 행동데이터를 분석함으로써 설문지 방식보다는 보다 직접적이고 객관적으로 학습자의 행동을 측정했다고 할 수 있다. 그러나 측정된 학습시간이 학습자가 실제 학습에 몰입한 시간은 아니다. 따라서 학습자의 실제적 학습을 보다 정확히 파악할 수 있는 지표에 대한 탐색이 이루어진다면 연구의 타당성을 보완할 수 있을 것이다.

이와 같은 제한점이 있지만, 본 연구는 기존 연구에서 관심을 받지 못했던 일반대학에서 e-러닝 학습자를 대상으로 LMS에 수집된 로그 데이터를 활용하여 중도탈락 예측모형을 개발하고 조기 적용에 대한 가능성을 탐색해 봄으로써 일반대학의 교양 e-러닝 강좌에서 중도탈락을 예방하는 수업 운영방안과 학습처방을 모색하는데 방향을 제공할 것으로 기대한다.

참 고 문 헌

- [1] 한국교육개발원 (2012). 2012 교육통계분석자료집: 평생교육통계편, 통계자료 SM 2012-13-3 ISSN 2287-9080.
- [2] 교육과학기술부 (2011). 사이버대학 운영 종합대책에 따른 자체계획 수립 및 시행. 교육과학기술부, 지식정보기반과.
- [3] 한국교육학술정보원 (2012). 대학이러닝통계. Retrieved September 10, 2013, from <http://www.rinfo.kr/>

- [4] 유홍준 · 정태인 (2012). 교양기초교육에서 사이버 강좌 운영 실태와 개선방안. **교양교육연구**, 6(3), 123-164.
- [5] Macfadyen, L. P., & Dawson, S. (2010). Mining LMS data to develop an “early warning system” for educators: A proof of concept. *Computer & Education*, 54, 588-599.
- [6] Wang, A. Y., & Newlin, M. H. (2002). Predictors of web-student performance: The role of self-efficacy and reasons for taking an on-line class. *Computers in Human Behavior*, 18, 151-163.
- [7] Campbell, J. P., DeBois, P. B., & Oblinger, D. G. (2007). Academic analytics: A new tool for a new era. *EDUCAUSE Review*, Retrieved December 10, 2013, from <http://net.educause.edu/ir/library/pdf/erm0742.pdf>
- [8] 조일현 · 김윤미 (2013). 이러닝에서 학습자의 시간관리 전략이 학업성취도에 미치는 영향: 학습분석학적 접근. **교육정보미디어**, 19(1), 83-107.
- [9] Elias, T. (2011). *Learning analytics: Definitions, processes and potentials*. Retrieved December 12, 2013, from <http://learninganalytics.net/LearningAnalyticsDefinitionsProcessesPotential.pdf>
- [10] 조일현 · 김정현 (2013). 학습분석학을 활용한 e-러닝 학업성과 추정 모형의 통계적 유의성 확보 시점 규명. **교육공학연구**, 29(2), 285-306.
- [11] Zaïane, O. R. (2001). Web usage mining for a better web-based learning environment. *Proceedings of Conference on Advanced Technology for Education, USA*, 60-64.
- [12] 임연옥 (2007). 사이버대학 학습자관련 변인과 중도탈락 간의 관계 규명을 위한 실증적 연구. **한국교육정보학회지**, 11(2), 1-14.
- [13] Carr, S. (2000). As distance education comes of age, the challenge is keeping the students. *Chronicle of Higher Education*, 46, 39 - 42.
- [14] 김현숙 · 박은영 (2011). 사이버대학 및 오프라인대학 학습자들의 사이버 강좌에 대한 반응과 학업성취도 차이. *Multimedia-Assisted Language Learning*, 14(3), 175-194.
- [15] 심미자 · 심영남 (2010). 사이버대학과 일반대학의 이러닝 상호작용 비교 연구. **교육방법연구**, 22(1), 55-76.
- [16] Morris, L. V., Finnegan, C. L., & Wu, S. (2005). Tracking student behavior, persistence, and achievement in online courses. *Internet and Higher Education*, 8, 221-231.
- [17] Dupin-Bryant, P. (2004). Pre-entry variables related to retention in online distance education. *American Journal of Distance Education*, 18(4), 199 - 206.
- [18] 전주성 (2010). 사이버대학의 잠재적 중도탈락자 예측에 관한 연구. *Andragogy Today: Interdisciplinary Journal of Adult & Continuing Education*, 13(1), 121-139.
- [19] Finnegan, C., Morris, L. V., & Lee, K. (2009). Differences by course discipline on student behavior, persistence, and achievement in online courses of undergraduate general education. *Journal of College Student Retention: Research, Theory and Practice*, 10(1), 39 - 54.
- [20] 주영주 · 심우진 · 김수미 (2008). 기업 사이버 교육에서 학습자의 중도탈락에 대한 결정요인 분석. **교육정보미디어연구**, 14(4), 5-25.
- [21] 주영주 · 장미진 · 이현주 (2007). 사이버대학 학생의 중도탈락 경험에 근거한 중도탈락 요인에 대한 질적 연구. **교육정보미디어**, 13(3), 209-233.
- [22] 최선 · 김광재 (2008). 웹기반 학습자의 중도탈락 요인에 관한 연구: H 사이버대학을 중심으로. **e-비즈니스 연구**, 9(2), 225-245.
- [23] Lee, Y., Choi, J., & Kim, T. (2013). Discriminating factors between completers of and dropouts from online learning courses. *British Journal of Educational Technology*, 44(2), 328-337.
- [24] Willging, P. A., & Johnson, S. D. (2009). Factors that influence students' decision to dropout of online courses. *Journal of*

- Asynchronous Learning Networks*, 13(3), 115-127.
- [25] Cohen, A., & Nachmias, R. (2011). What can instructors and policy makers learn about Web-supported learning through Web-usage mining. *Internet and Higher Education*, 14, 67-76.
- [26] Rafaeli, S., & Ravid, G. (1997). Online, web-based learning environment for an information systems course: Access logs, linearity and performance. *Proceedings of Information Systems Educators Conference, USA*, 97, 92 - 99.
- [27] Mazza, R., & Milani, C. (2005, July). *Exploring usage analysis in learning systems: Gaining insights from visualisations*. Paper presented at the 12th International Conference on Artificial Intelligence in Education, Amsterdam, Netherlands.
- [28] Bienkowski, M., Feng, M., Means, B. (2012). *Enhancing teaching and learning through educational data mining and learning analytics*. Washington, DC.
- [29] Johnson, L., Smith, R., Willis, H., Levine, A., and Haywood, K. (2011). *The 2011 horizon report*. Austin, Texas: The New Media Consortium.
- [30] Purdue University. (2013). *Course signals*. Retrieved November 25, 2013, from <http://www.itap.purdue.edu/learning/tools/signals/>
- [31] Picciano, A. G. (2012). The evolution of big data and learning analytics in American higher education. *Journal of Asynchronous Learning Networks*, 16(3), 9-20.
- [32] 강민석 · 김진일 · 박인우 (2009). 사이버대학 e-러닝환경에서 학업성취도에 영향을 미치는 학습 참여 변인 규명. **인터넷정보학회논문지**, 10(5), 135-143.
- [33] Elvers, G. C., Polzella, D. J., & Graetz, K. (2003). Procrastination in online courses: Performance and attitudinal differences. *Teaching of Psychology*, 30(2), 159-162.
- [34] Tuckman, B. W. (2005). Relations of academic procrastination, rationalizations, and performance in a web course with deadlines. *Psychological Reports*, 96, 1015 - 1021.
- [35] 아주대학교 (2013). 사이버 강의 수강안내. Retrieved December 12, 2013, from <http://www.ajou.ac.kr/kr/life/class04.jsp>
- [36] 한양대학교 (2013). 수업 진행. Retrieved December 10, 2013, from <https://portal.hanyang.ac.kr/lms/main/htmlPage/doHtmlPageView.do#>
- [37] 성태제 · 시기자 (2006). **연구방법론**. 서울:학지사.
- [38] 권성연 (2009). e-Learning 환경에서 성인학습자의 학습시간 계획 실천 수준에 따른 학습참여, 학습지연, 학습시간, 학업 성취 차이 분석. **학습자중심교과교육연구**, 9(3), 61-86.
- [39] 이인숙 (2002). e-Learning 학습전략 수준 및 학업성취도 규명. **교육공학연구**, 18(2), 51-67.
- [40] Loomis, K. D. (2000). Learning styles and asynchronous learning: Comparing the LASSI model to class performance. *Journal of Asynchronous Learning Networks*, 4(1), 23-31.



유 지원

1991 이화여자대학교
전자계산학과(B.S.)

1996 University of Minnesota
교육학석사,
교육공학전공(M.Ed.)

2011 이화여자대학교 교육공학 박사(Ph.D.)

1999~2002 이화여자대학교 정보통신연구소
멀티미디어 과정 주임교수

2007~2011 가천대학교 선임연구원

2012~현재 이화여자대학교 교육공학과 연구교수
관심분야: 학습환경 설계, 미래역량, 학업정서

E-mail: you.jiwon@gmail.com