

학생 중도탈락 예측지수에 관한 사후검증 연구

Post-Examination Analysis on the Student Dropout Prediction Index

이지은

한양사이버대학교 경영정보·AI비즈니스학과

요약

학습자 중도탈락은 사이버대학이 해결해야 할 과제 중 하나이다. 2019년도 기준으로 사이버대학의 전체 학생 수는 13만여 명에 달하고 있으나, 중도탈락 비율도 매우 높은 편이다. 중도탈락율을 낮추기 위해 사이버대학은 학습 분석에 많은 투자를 하고 있다. 특히 일부 사이버대학에서는 중도탈락 가능성을 정량적으로 분석하여 중도탈락이 우려되는 학생에 대한 지원을 강화하고 있다. 본 논문의 목적은 중도탈락 예측지수에 영향을 미치는 학습데이터를 규명하는데 있다. 분석 결과, 수강 차시(진도율), 이수학점, 평점, 휴학 횟수가 중도탈락에 유의미한 영향을 미치는 것으로 확인되었다. 사이버대학은 학생 중도탈락 예측지수에 관한 사후검증을 통해 예측 모델의 정확도를 높여나가야 할 것이다.

■ 중심어: 사이버대학, 학습 분석, 학습자 중도탈락, 사후검증

Abstract

Drop-out issue is one of the challenges of cyber university. There are about 130,000 students enrolled in cyber universities, but the dropout rate is also very high. To lower the dropout rate, cyber universities invest heavily in learning analytics. Some cyber universities analyze the possibility of dropout and actively support students who are more likely to drop out. The purpose of this paper is to identify the learning data affecting the dropout prediction index. As a result of the analysis, it is confirmed that number of lessons(progress), credits, achievement and leave of absence have a significant effect on dropout rate. It is necessary to increase the accuracy of the prediction model through post-test on the student dropout prediction index.

■ Keyword: Cyber University, Learning Analysis, Student Dropout, Post-Examination

I. 서론

기술의 진보로 언제 어디서나 학습할 수 있는 환경이 마련되면서 교육의 기회는 점점 더 넓어지고 있다. 이는 사이버대학에 큰 기회요인이 되고 있으며, AI, 빅데이터, 가상현실 등 첨단 기술을 이용하여 개별화 학습을 지원하고 현장감 있는 교육을 제공하는 역량은 사이버대학의 핵심 경쟁력이 되고 있다.

2000년 평생교육법 개정을 계기로 사이버대학의 법적 근거가 마련되면서 2001년 3월 대한민국 최초로 9개 사이버대학(학사과정 7개교, 전문학사과정 2개교)이 개교한 이래 2019년 현재 19개의 사이버대학(학사과정 17개교, 전문학사과정 2개교)이 운영되고 있다. 재적 학생은 2011년 6000명에서 13만 명으로 20배 이상 늘어났는데, 재적 학생 수로 국내 최대 규모인 H사이버대학의 경우 2018년 기준으로 재적 학생이 16,569명에 달한다. 대학알리미에서 제공하는 대학정보공시¹⁾ 정보를 보면 2018년도 17개 대학의 재적학생 평균은 6,870명으로 사이버대학에서 학업을 하는 학생 수는 큰 규모로 증가했지만, 중도이탈을 또한 높은 편이다.

중도이탈 증가는 대학의 재정적 손실로 이어지지만 개인의 경쟁력에도 부정적인 영향을 미친다. 사이버대학의 경우 학위 취득 목적 뿐 아니라 경력개발이나 전직에 필요한 역량을 강화하기 위해 입학하는 학생들이 많은데, 사이버대학에서 중도탈락할 경우 학습 의욕과 자신감이 저하되고, 그로 인해 고등교육체제로부터 이탈함으로써 개인의 경쟁력을 강화할 수 있는 기회 상실로 이어진다.

본 논문에서는 학습 중도탈락 가능성을 예측하는 시도에 대한 실증연구를 실시하였다. 이를 위해 국내 A사이버대학교에서 도입한 중도탈락 예측지수에 관한 사후검증을 통해 중도탈락 예측

에 필요한 핵심 변수를 도출하고 중도탈락을 낮추기 위한 교수자의 역할을 제안하고자 한다.

II. 이론적 배경

2.1 사이버대학교 중도탈락 원인

사이버대학은 언제 어디서나 학습이 가능하고, 학비가 저렴하며, 선발기준이 유연하다는 이유로 경력개발 요구가 있는 성인학습자에게 고등교육을 위한 좋은 대안이 되고 있다. 일반대학에서도 MOOC나 자체개발한 이러닝 과정을 학점과정으로 제공하고 있고 군 복무 중 학점을 취득할 수 있는 군 이러닝(e-learning) 제도가 도입되면서 이러닝에 대한 수요와 공급이 지속적으로 늘어날 전망이다. 이에 많은 대학들이 이러닝을 개발하여 서비스를 제공하고 있지만 학생들이 성실하게 학습을 지속하기란 쉽지 않으며[1], 이는 물리적 구속력이 없는 사이버대학일수록 더욱 그러하다. 2018년도 기준 사이버대학의 재학생 중도탈락 비율은 18.8%에 달한다. 이는 일반 대학교(6.05%, 교육대학, 기술대학, 각종학교 제외)의 3배에 이르는 수치다. 이처럼 중도탈락율이 높은 이유는 사이버대학교에 재학하는 학생의 상당수가 일과 학습을 병행하고 있고, 자기주도적 학습역량이 부족하기 때문으로 해석된다. 이러닝 학습자들은 면대면 학습보다 더 빈번하게 어려운 학습 상황에 놓이게 되며 학습을 위해서도 더 많은 노력이 요구된다[2]. 사이버대학은 직장, 가사, 사업을 병행하는 성인학습자 비중이 높는데 학업의 우선순위가 다른 일에 밀리거나 무분별한 전공 선택, 부족한 자기조절 능력 등으로 학업을 포기하는 경우가 많으며, 체계적이고 밀도 있는 상담 기회도 부족한 편이어서 학업을 그만두기로 맘먹은 학생들을 설득하기란 쉽지 않다[3].

실제로 사이버대학에서 중도탈락 배경변인을

1) <https://www.academyinfo.go.kr/index.do>

〈표 1〉 재적 학생 수 및 중도탈락율

지역	학교	재적학생(명)	중도탈락율(%)
대전	A사이버대학교	3,493	7.2
서울	B사이버대학교	10,228	23.6
서울	C사이버대학교	10,375	17.7
경기	D사이버대학교	3,375	17
충남	E사이버대학교	2,381	16.2
경북	F사이버대학교	4,938	19.1
서울	디지털G대학교	4,670	18.4
부산	H디지털대학교	2,649	16.2
서울	사이버I대학교	7,305	20.7
서울	J디지털대학교	12,778	20.5
서울	K사이버대학교	11,340	20.7
서울	L사이버대학교	7,421	18
서울	M사이버대학교	6,329	13.2
전북	N디지털대학교	6,306	13.1
서울	O사이버대학교	5,327	19.7
서울	P사이버대학교	16,569	20
부산	Q사이버대학교	1,311	39.6
평균		6,870	18.8

* 대학정보공시(2018년 기준, 17개 대학)

분석한 연구를 보면 학습시간 부족, 경제적 어려움, 온라인교육 부적응, 사이버대학의 낮은 인지도를 꼽고 있는데[4], 이러닝 학습에 대한 부적응과 학습시간 부족 문제는 교수자의 수업운영 전략과 학습 컨설팅을 통해 보완이 가능한 영역이다. 하지만 이러닝 학습에 있어 가장 중요한건 학업에 임하는 학습자의 자세이다. Tinto는 학습자 스스로의 헌신이 중도탈락을 막는 핵심요소라고 주장했는데[5], 이는 강의 수강 및 학습에 투입하는 시간적 노력과 학업성취도가 학습 지속과 통계적으로 유의한 관계가 있다고 보는 전문가들의 견해와 맥락을 같이 한다. 일례로 전주성(2010)은 총 학습시간과 강의접속 수가 높을수록 과정 수료 가능성이 높아짐을 실증한 바 있는데[6], 이는 자신이 투입한 노력에 대한 보상심리가 학업의지를 강하게 만드는 순기능을 하기 때문으로 분석된다. 하지만 학생의 능력이 부족해도 교육기관의 관리 역량에 따라 중도탈락은 크게 줄어들 수 있다[7]. 특히 학생의 학사관리와 학습을 지원하는 교수자의 역할은 매우 중요하다. 중도이탈을

낮추기 위해 교수자는 두가지 방안을 고민하게 된다. 하나는 과정이수 요건을 낮추는 것이며, 하나는 중도이탈 가능성이 있는 학습자를 집중적으로 지원하는 것이다. 전자의 경우 단기적으로는 효과가 있을지 모르나 짧게는 2년(편입)에서 길게는 4년 이상 학업의지가 없는 학생을 졸업까지 끌고 가기란 불가능하여 이는 근본적인 해결책이 될 수 없다. 오히려 분명한 목표와 충실한 학습이 중도이탈을 막는 핵심변수로 보고 학습자의 지속적이고 성실한 학습을 독려하는 교수자의 ‘핀셋 처방’이 효과적이다. 특히 학습자를 압박하지 않는 교수자의 은근한 개입이 효과를 발휘하는 경우가 많다. 인지과학에 기초한 행동경제학은 인간의 사고와 행동에 관한 실증적 연구 성과와 축적된 실증자료를 바탕으로 넛지(nudge)라는 처방적 의사결정 이론을 구축하였다[8]. 넛지는 드러나지 않는 자연스러운 개입으로 사람들의 올바른 행동을 이끈다. 넛지 전략은 마케팅이나 공간디자인에서 주로 활용되고 있는데, 최근에는 교육현장에서도 많이 활용되는 추세이다[8]. 넛지의

핵심은 사람들이 어떤 행동을 하도록 강요하는 것이 아닌, 바람직한 행동을 하도록 가벼운 자극을 주어 올바른 선택을 부드럽게 유도하는 것인데, 일반대학이 아닌 사이버대학에서 넷지 전략의 활용은 매우 중요하다. 이는 성인학습자의 경우 필요 이상의 개입이 학습에 대한 부담이나 반감과 같은 심리적 부작용을 가져오기 때문이다. Bernard 등(2009)이 실시한 메타분석 연구에 따르면, 이러닝 환경에서는 학습자-학습자, 학습자-콘텐츠, 학습자-교수자 순으로 상호작용이 효과를 보이는 것으로 나타났는데, 이는 교수와의 상호작용에서 오는 학습자의 심리적 부담감 때문으로 해석된다[9]. 즉, 교수자의 지나친 참견과 개입이 학생들을 심리적으로 압박하고 학습 경험을 경직되게 만들 수 있으므로 학습자의 바람직한 행동을 유발하는 자연스러운 맥락 기반의 상호작용이 필요하다. 이를 위해 교수자는 넷지가 필요한 대상과 시점, 방법을 스스로 찾아야 하는데 학습 분석을 통해 유용한 단서를 얻을 수 있다.

2.2 학습데이터와 학습 분석

모든 학습활동과 학습관리가 전자적으로 이뤄지는 이러닝 환경에서는 다양한 유형의 학습데이터가 발생한다. 이를 분석하면 학습자가 충실하게 학습을 하는지, 학습자들의 성취도는 어떠한지, 성취도가 크게 낮은 학습자는 누구인지에 대한 정보를 얻을 수 있다. 이러닝을 통해서는 데이터 생성과 수집이 용이하고, 보다 정교한 분석과 모델링이 가능하기 때문에[10], 사이버대학에서는 학습자의 성취도나 인구통계학적 특성에 따른 학습양식 분석 결과를 제공함으로써 교수자가 학습자에게 적합한 개별화 서비스를 제공하도록 지원하고 있다.

일반적으로 학습데이터는 학습콘텐츠 데이터, 학습활동 데이터, 학습자 프로파일 데이터, 운영 데이터, 경력 데이터로 구분된다[11]. 학습콘텐츠

데이터는 학습목표, 강의, 멀티미디어 관련 데이터이고, 학습활동 데이터에는 퀴즈, 과제, 읽기, 협업 등 실제적인 학습을 통해 발생하는 데이터이며, 학습자 프로파일 데이터는 학습자 연령, 학력, 경력 정보와 같은 인구통계학적 정보를 포함한다. 운영 데이터에는 학습자가 수강한 과정, 강의, 학위 등 학적 정보를 포함하며 경력 데이터에는 교육 이력, 직업, 멘토링 데이터가 포함된다. 이중 학습활동 데이터와 학습자 프로파일 데이터는 대부분의 LMS에서 공통적으로 제공되는 데이터로, 해당 데이터를 분석하여 중도이탈 가능성이 높은 학습자와 우수학습자의 학습 패턴을 각각 분석한 후 이를 모델링하면 필요한 시점에서 학습자 개인에게 적합한 처방적 조치를 제공할 수 있게 된다. 대학 등 교육기관에서는 회귀분석이나 의사결정나무, 기계학습 등 예측분석(Predictive Analytics)을 통해 학업이탈에 대한 예측을 시도하고 있는데, 학습자 학적 정보와 학업 성취도와 같은 기준 데이터와 총 학습시간, 강의 접속 수, 토론 참여 빈도, 시험응시 여부와 같은 학습활동 데이터를 분석하여 학습자의 성취도와 몰입도, 이탈 가능성을 예측하고 있다. 교수자는 분석 결과를 토대로 학습자 수준에 맞는 처방적 조치를 실시하여, 그러한 결과로 학습자의 학습 지속 의지와 만족도를 강화할 수 있다. 일례로 이탈 가능성이 높아지는(위험 지수가 상승하는) 학습자를 특별관리 학습자로 설정하고, 이들의 학습 진도를 지속적으로 모니터링하면서 개별화된 메시지(문자, 쪽지 등)로 학업 독려와 시험응시 안내를 제공하면 학습 참여율이 높아지는 즉각적인 효과가 나타나게 된다. 이러한 경험이 축적되면 학습자를 관리하는 노하우가 교수자의 개인지로 전환이 되는 것이다. 이러한 이유로 선도적인 사이버대학교들은 중도탈락 가능성이 있는 학습자 정보를 교수자에게 공유하고 있다.

하지만 학생의 중도탈락을 정확하게 예측하기 위해서는 예측 알고리즘을 정교화해야 한다. 중

도이탈 판단 기준은 상황과 맥락에 따라 다르고 예측 알고리즘은 학생 또는 교육자의 의사결정을 자동화하는 것이 아닌, 정확도가 높도록 도와주는 데 그 목적이 있으며[10], 초기 알고리즘은 정확도가 떨어질 수 있어 이후 발생하는 데이터를 입력하여 알고리즘을 정교화 하는 노력이 필요하다. 따라서 예측 알고리즘의 결과 값을 맹신하기 보다는 결과에 대한 신뢰도를 스스로 판단하고 보완해나가는 노력이 필요하다.

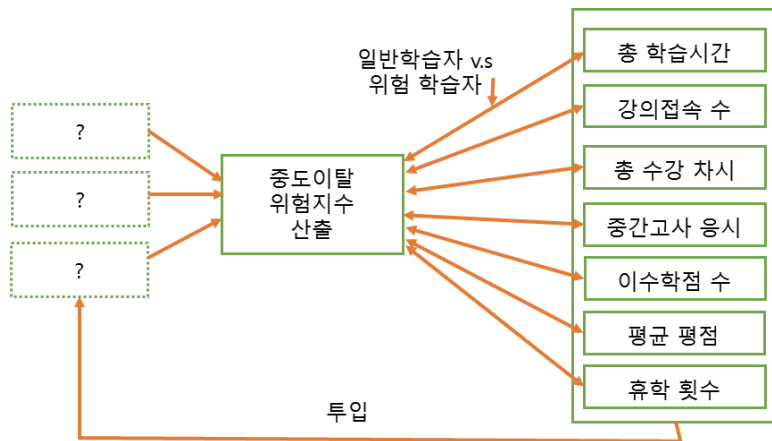
습이력 정보와 함께 제공함으로써 중도이탈 가능성이 높은 학생에 대한 밀착관리를 지원하고 있다. 중도이탈 위험수치만 제공할 뿐 예측모델에 대해서는 공개하지 않고 있으며, 지난 9월부터 해당 정보가 제공되고 있어 아직까지는 예측 모델이 정교하지 않을 것으로 예상된다. 연구자는 LMS에서 제공하는 학습자별 중도이탈 예측지수의 신뢰성을 검증하기 위해 2학기 개강시점부터 12차시까지 학생들의 학습 이력을 추적 조사하였다. 그 결과를 토대로 일반 학습자와 중도탈락 위험군의 학습 패턴에 통계적으로 유의한 차이가 있는지를 분석하였으며, 학습자의 학습 이력과 중도탈락 예측지수(위험도)의 상관관계를 분석하였다.

III. 실증분석

3.1 분석 목적 및 내용

연구자가 강의하는 사이버대학에서는 학습자별 중도이탈 가능성을 수치 자료로 변환하여 학

실증분석을 위해 연구자가 개설한 2개 과목을 수강하고 있는 301명의 학습자 중 학업중단 가능성을 나타내는 수치가 부여되지 않은, 즉 신입생



〈그림 1〉 연구 설계

〈표 2〉 집단구분 및 분석대상

구분	유형		
집단	일반학습자		
	위험학습자		
변수	독립변수	학습정보	총 학습시간, 강의접속 수, 총 수강 차시, 중간고사 응시
		학사정보	이수학점 수, 평균 평점, 휴학 횟수
	종속변수	중도탈락 위험도(0~5)	

을 제외한 총 282명의 학습이력 정보를 분석하였다. 282명 중 중도탈락 위험이 있는 학습자(위험 학습자)는 34명으로, 전체 학습자의 12%를 차지하였으며, 분석에 사용한 데이터는 학습자의 총 학습시간, 강의접속 수, 총 수강차시, 중간고사 응시정보(이상 학습정보)와 이수학점 수, 평균 평점, 휴학 횟수(이상 학사정보)이다. 집단구분 및 분석대상은 <표 2>와 같다.

3.2 분석 결과

3.2.1 학습정보와 학사정보 평균비교

일반 학습자와 위험 학습자의 총 학습시간, 강의접속 수, 총 수강 차시, 중간고사 응시여부, 이수 학점 수, 평균 평점, 휴학 횟수 사이에 통계적으로 유의한 차이가 있는지를 확인하기 위해 독립표본 검정(t-test)을 실시하고 Levene의 검정방법(Levene's test)을 통해 등분산 여부를 검증하였다.

먼저 총 학습시간은 일반 학습자가 평균 1,088분이었고 위험 학습자는 평균 1,020분으로 나타났다. 강의접속 수는 일반 학습자가 24.6회, 위험 학습자가 23.3회였으며, 휴학 횟수는 일반 학습자가 0.11회, 위험 학습자가 0.26회로 이들 간에는 통계적으로 유의한 차이가 발견되지 않았다. 중간고사 응시 여부도 일반 학습자와 위험 학습

자 사이에 차이가 없었다. 그러나 총 수강차시의 경우 일반 학습자는 11.7차시, 위험 학습자는 10.7차시로 통계적으로 유의한 차이가 있었으며 ($t=2.257, p<.05$), 이수학점 수는 일반 학습자가 78학점, 위험 학습자가 57.8학점으로($t=3.017, p<.01$), 평점은 일반 학습자가 4.03점(4.5점 만점), 위험 학습자는 2.58점으로 나타나($t=8.788, p<.001$) 일반학습자의 경우 학습정보에서는 총 수강차시에서, 학사정보에서는 이수학점 수와 평균 평점에서 위험 학습자에 비해 높은 성취도를 나타내는 것으로 분석되었다. 일반 학습자와 중도탈락 위험학습자의 학습패턴 분석 결과는 <표 3>과 같다.

3.2.2 학습과 학사관련 변수가 중도탈락 위험도에 미치는 영향

학습자의 학습정보와 학사정보가 중도탈락 위험도에 미치는 영향을 분석하기 위해 중다선형회귀분석(Multiple Linear Regression)을 실시하였다. 분석에 앞서 총 학습시간, 강의접속 수, 이수학점 수, 평균 평점은 5점 척도로 변환했는데, 가령 평점의 경우 4.0 이상은 5, 3.5이상 4.0 미만은 4, 3.0이상 3.5 미만은 3, 2.5이상 3.0 미만은 2, 2.5 미만은 1로 코딩을 한 후 분석을 실시하였다.

분석 결과, 자기상관 정도를 나타내는 더빈왓슨

<표 3> 일반 학습자와 중도탈락 위험학습자의 학습패턴 분석 결과

구분	학습자 집단		t-value	p-value
	일반 학습자	중도탈락 위험학습자		
총 학습시간	1088.4476	1020.2353	0.649	0.517
강의접속 수	24.6008	23.3235	0.262	0.793
총 수강 차시	11.7379	10.7353	2.257	0.03**
중간고사 응시	1.96	1.88	1.493	0.144
이수학점 수	78.02	57.85	3.017	0.004***
평균 평점	4.0324	2.5882	8.788	0.000***
휴학 횟수	0.1169	0.2647	-1.350	0.185

* $p<0.1$, ** $p<0.05$, *** $p<0.01$

(Durbin- Watson)값은 2.155로 자기상관은 없다고 판단했으며, 분산분석(ANOVA) 결과 독립변수의 기울기가 0이라는 가설이 기각되어(sig=.000) 회귀선의 모델이 적합한 것으로 판단하였다.

독립변수와 종속변수의 적률상관관계를 나타내는 R Square 값은 .350로 독립변수가 종속변수의 35%를 설명하고 있었다. 총 학습시간, 강의접속 수, 총 수강 차시, 중간고사 응시, 이수학점 수, 평균 평점, 휴학 횟수가 중도탈락 위험도에 미치는 영향력을 분석한 결과, 학습자의 총 수강차시($t=-2.878, p<.05$)와 평균 평점($t=-9.717, p<.01$)은 중도탈락 위험도에 영향을 미치는 반면, 총 학습시간과 강의접속 수, 중간고사 응시는 통계적으로 유의미한 영향을 미치지 않는 것으로 분석되었다. 다만 유의도(sig.)를 0.1까지 높일 경우 이수학점 수와 휴학 횟수도 중도탈락 위험도에 영향을 미치는 것으로 나타났는데, 일반적으로 유의도를 0.05로 설정하는 이유는 Fisher가 이 정도의 값을 기준으로 유의성을 결정하면 괜찮다고 제시했기 때문으로, 본 연구에서는 설명력을 가지는 변수를 최대한 도출하기 위해 오차허용범위를 10%까지 설정하여 중도탈락 위험에 영향을 미치는 변수를 도출하였다. 중다선형회귀분석 결과는 <표 4>와 같다.

3.3 분석결과의 활용

이상의 분석결과를 통해 볼 때, 학습정보에서는 총 수강 차시가, 학사정보에서는 이수학점 수와 평균 평점, 휴학 횟수가 중도탈락 위험도에 영향을 미치는 것을 알 수 있다. 학사정보의 경우 과거 학습이력을 토대로 한 정적 정보이고, 학습정보는 실제 학습과정에서 발생하는 동적 정보인데 이 두 가지가 모두 중도탈락에 영향을 미치므로 교수자는 과거 정보(정적 정보) 뿐만 아니라 학습 과정에서 발생하는 동적 정보를 지속적으로 확인하여 학습자별로 적합한 조치를 취해야 한다. 또한 중도탈락 위험지수가 완벽하지 않다는 가정 하에 이수학점 수와 평균 평점, 휴학 횟수를 고려하여 은근한 개입과 지원이 필요한 학습자를 식별한 후 학습 진행이 지연되는, 즉 결석이나 지각이 반복되기 시작하는 시점부터 학습 참여를 독려하는 개별화 메시지를 전달하여 학습 진도가 밀리지 않도록 하는 조치가 이뤄져야 한다. 실제로 개강 1개월(4차시) 후 중도탈락 위험도가 높은 학습자의 진도를 점검한 결과 79.4% 가량이 3차시 이상 진도가 밀리는 상황이었는 데, 쪽지와 메일을 통해 학습참여를 독려한 결과 6차시 시점에서는 20.5%로 그 수치가 낮아지는 것이 확인된 바 있다.

<표 4> 학습과 학사관련 변수가 중도탈락 위험도에 미치는 영향

종속변수	독립변수	비표준화 계수		표준화 계수	t	sig.
		B	표준화 오류	베타		
중도탈락 위험도	(상수)	2.974	.308		9.671	.000
	총 학습시간	.003	.020	.008	.156	.876
	강의접속 수	.020	.021	.053	1.000	.318
	총 수강 차시	-.071	.025	-.171	-2.878	.004**
	중간고사 응시	.202	.153	.073	1.315	.190
	이수학점 수	-.049	.026	-.092	-1.870	.063*
	평균 평점	-.343	.035	-.521	-9.717	.000***
	휴학 횟수	.112	.062	.092	1.826	.069*
R = .591, R 제곱 = .350, 수정된 R 제곱 = .333, F = 20.982, p=.000, Durbin-Watson=2.155						

*p<0.1, **p<0.05, ***p<0.01

IV. 결 론

4.1 연구 결과 및 시사점

대학생의 중도탈락은 학업지속 여부에 관한 대학생 개인의 선택적 문제가 아니라 대학과 정부가 관심을 가져야 할 정책적 문제이다[12]. 대학생활에 대해 긍정적으로 사고할수록 학업중단의도는 낮아지기 때문에 교수자는 학사지도와 상담을 통해 건전한 교육적 목표와 직업적 목표를 세워주고 삶의 목표를 달성할 수 있도록 학습자를 지원해야 한다. 특히 일과 학습을 병행하는 학습자가 많은 사이버대학의 경우 학습량 부족과 학습 지연으로 학업을 중단하는 사례가 많은 만큼 학습자의 학습상황을 면밀하게 관찰하고 적절한 시점에 자연스럽게 개입하여 중도이탈을 막는 교수자의 역할이 중요하다.

현재 상당수의 사이버대학에서는 LMS 상에서 학습자의 성취도와 학습 여정을 확인할 수 있는 다양한 정보들을 제공하고 있다. 특히 중도탈락 위험지수처럼 이상 징후를 알려주는 정보는 대학과 교수자에게 매우 유용하다. 그러나 잘못된 예측으로 불필요한 개입이 이뤄지거나 개입이 필요한 학습자가 방치될 수 있으므로 예측 정보의 정확도와 신뢰도를 높이기 위해 지속적인 사후검증 과정이 요구된다. 특히 교수자는 예측정보를 참고하여 학습자에게 취했던 다양한 넛지 행위의 효과성을 분석하여 학습자의 수준과 상황에 맞는 상호작용 전략을 마련함으로써 교수 자신의 경쟁력을 강화할 수 있을 것이다.

학생 충원율과 중도탈락율은 사이버대학의 재정 건전성과 브랜드 가치에 영향을 미치고 그에 따라 학생 모집도 영향을 받으므로 사이버대학은 학생 모집뿐만 아니라 중도탈락 예방에도 적극적인 노력을 기울여야 할 것이며, 노력의 성과를 극대화하기 위해서는 조직의 경험치가 아닌 학습데이터와 예측모델을 적극적으로 활용하는 과학적

접근이 필요할 것이다.

4.2 연구의 의의와 한계

본 연구의 목적은 중도탈락 예측지수에 관한 사후검증을 통해 중도탈락 예측에 필요한 핵심 변수를 식별하는 것이다. 최근들어 학습 데이터를 분석하여 중도탈락 가능성을 예측하는 서비스가 제공되기 시작했는데, 사후검증을 통해 핵심 변수를 규명한 국내 연구는 아직까지 확인된 바 없다. 본 연구서는 LMS에서 기본적으로 제공되는 학습 데이터를 이용하여 검증을 실시했으나, 이 외에도 중도탈락에 영향을 미치거나 중도탈락 가능성을 미리 알려주는 변수는 더 있을 것으로 예상된다. 특히 총 수강 차시, 이수학점, 평균 평점, 휴학 횟수와 같은 산출값(Output) 뿐만 아니라 학업 목적, 직업과 전공의 관련성, 선수 지식과 같은 학습자 특성도 중도탈락 가능성에 영향을 미칠 것으로 예상된다. 따라서 향후 연구에서는 사이버대학의 중도탈락에 영향을 미치는 변수에 대한 포괄적인 선행조사를 실시하고, 다양한 변수의 영향력을 분석하는 보다 정교한 연구 설계와 깊이있는 분석을 진행하고자 한다.

참 고 문 헌

- [1] Carr, S.(2000). As distance education comes of age, the challenge is keeping the students. *Chronicle of Higher Education*, 46(23), 39-41.
- [2] Elvers, G.C., Polzella, D.J. & Graetz, K.(2003). Procrastination in online courses: Performance and attitudinal differences. *Teaching of Psychology*, 30(2), 159-162.
- [3] 임연옥, 이광희(2003). 사이버대학 재학생의 중도이탈 문제에 관한 탐색적 연구. *한국교육*, 30(3), 321-348.

- [4] 임연옥(2007). 사이버대학 학습자관련 변인과 중도탈락 간의 관계 규명을 위한 실증적 연구. *한국정보교육학회*, 11(2), 205-219.
- [5] Tinto, V.(1975). Dropout from higher education: A theoretical synthesis of recent research. *Review of Educational Research*, 45(1), 89-125.
- [6] 전주성(2010). 사이버대학의 잠재적 중도탈락자 예측에 관한 연구. *Andragogy Today: International Journal of Adult & Continuing Education*, 13(1), 121-139.
- [7] Hutagaol, N. & Suharjito, S.(2019). Predictive modelling of student dropout using ensemble classifier method in higher education. *Advances in Science, Technology and Engineering Systems Journal*, 4(4), 206-211.
- [8] 문경호(2018). 도덕교육에서 넷지의 활용 가능성에 대한 고찰. *교원교육*, 34(4), 193-215.
- [9] Bernard, R.M., Abrami, P.C., Borokhovski, E., Wade, A., Tamim, R., Surkes, M.A., & Bethel, E.C.(2009). A meta-analysis of three interaction treatments in distance education. *Review of Educational Research*, 79(3), 1243-1289.
- [10] 권영옥(2019). 교육 데이터와 분석 기법: 사례 연구를 중심으로. *한국빅데이터학회지*, 4(1), 73-81.
- [11] IMS Global(2013). *Learning Measurement for Analytics Whitepaper*.
- [12] 채재은(2011). 대학생들의 휴학 요인 분석. *교육행정학연구*, 29(1), 295-317.

저자 소개



이지은(Ji-Eun Lee)

- 한양대학교 교육공학과 (이학사)
- 한양대학교 정보기술경영학과 (석사)
- 한양대학교 정보기술경영학과 (박사)

- 현재 : 한양사이버대학교 경영정보·AI비즈니스학과 조교수
- 관심분야 : 기술경영, 기술창업, 에듀테크, 인력양성