

머신러닝을 이용한 학업중단 위기학생 관리시스템의 설계

반재훈* · 김동현** · 하종수***

Design of the Management System for Students at Risk of Dropout
using Machine Learning

Chae-Hoon Ban* · Dong-Hyun Kim** · Jong-Soo Ha***

요약

학업을 중단하는 학생들의 비율이 해마다 증가하고 있어 대학은 학업중단을 막기 위하여 위험요소를 파악하고 이를 사전에 제거하기 위해 노력하고 있다. 그러나 특정 위험요소의 단변수 분석을 통해 위기학생을 관리하고 있어 예측이 부정확한 문제가 발생하고 있다. 본 연구에서는 이러한 문제점을 해결하기 위하여 학업중단 위험요소를 파악하고 학업중단 예측을 위해 머신러닝 방법을 통해 다변수 분석을 실시한다. 또한 다양한 예측방법별로 성능평가를 수행하여 최적화 방법을 도출하고 학업중단을 발생시키는 위험요소간의 연관성과 기여도를 평가한다.

ABSTRACT

The proportion of students dropping out of universities is increasing year by year, and they are trying to identify risk factors and eliminate them in advance to prevent dropouts. However, there is a problem in the management of students at risk of dropping out and the forecast is inaccurate because crisis students are managed through the univariable analysis of specific risk factors. In this paper, we identify risk factors for university dropout and analyze multivariables through machine learning method to predict university dropout. In addition, we derive the optimization method by evaluation performance for various prediction methods and evaluate the correlation and contribution between risk factors that cause university dropout.

키워드

Deep Learning, Machine Learning, Multivariable Analysis, School Dropout, Student Management System
딥러닝, 머신러닝, 다변수 분석, 학업 중단, 학생 관리 시스템

1. 서론

학령인구가 감소하고 대학 입학정원이 고교졸업자 수를 초과하면서 대학은 입학자원을 확보하려는 무한

경쟁의 시대에 돌입하였다. 또한 코로나로 인해 학업을 중단하는 학생들의 비율이 증가하여 대학은 심각한 재정위기에 몰리고 있으며 이는 교육의 질 하락으로 이어져 학생이 직접적인 피해를 입게 되는 악순환

* 고신대학교 IT경영학과(chban@kosen.ac.kr)

** 교신저자 : 동서대학교 컴퓨터공학부

*** 경남정보대학교 방송영상과(hajs@eagle.kit.ac.kr)

• 접수일 : 2021. 10. 22

• 수정완료일 : 2021. 11. 19

• 게재확정일 : 2021. 12. 17

• Received : Oct. 22, 2021, Revised : Nov. 19, 2021, Accepted : Dec. 17, 2021

• Corresponding Author : Dong-Hyun Kim

Division of Computer Engineering, Dongseo University

Email : pusover@dongseo.ac.kr

이 발생할 수 있다.

대학은 학생의 학업중단을 막기 위하여 다양한 방법을 시도하고 있는데 대부분의 대학들이 학업중단 위험요소를 파악하고 이를 사전에 제거하기 위해 노력하고 있다. 이러한 상황에서는 무엇보다도 학업중단 위기학생을 예측하는 것이 중요한데 기존의 시스템에서는 직전학기 성적이나 출석상황 등과 같은 단변수 분석을 통해 위기학생을 관리하고 있어 예측이 부정확한 문제가 발생하고 있다. 본 연구에서는 이러한 문제점을 해결하기 위하여 학업중단 위험요소를 파악하고 학업중단 예측을 위해 머신러닝 방법을 통한 다변수 분석을 실시하고 성능평가를 수행한다.

본 논문의 구성은 다음과 같다. 2장에서는 학업중단 위기학생에 관련된 다양한 관련연구를 살펴보고 3장에서는 위기학생 관리를 위해 실제 사용되고 있는 시스템을 소개하고 이에 대한 문제점을 기술한다. 그리고 4장에서는 학업중단 위험요소 파악하고 학업중단 예측을 위해 머신러닝 방법을 사용하여 분석을 실시한다. 또한 다양한 예측방법의 성능평가를 통해 최적화 방법을 도출한다. 마지막 5장에서는 결론 및 향후 연구에 대해 기술한다.

II. 관련 연구

중도탈락에 관련된 연구는 원인분석을 통해 위험요소를 차단하는 연구와 중도탈락을 예측하여 예방하는 연구가 있으며 대학의 중도탈락이 증가함에 따라 활발히 진행되고 있다. 대학생의 중도탈락에 영향을 미치는 대학의 요인을 분석하기 위하여 대학 알리미 포털을 통해 원시자료를 받아 대학의 종류를 나누어 중도탈락률을 종속변수로 다중회귀 분석을 실시하거나 학생의 설문 조사 자료를 활용하여 중도탈락 예측 모형을 구축하였다. 또한 대학의 학사 데이터베이스에 저장된 데이터로부터 주요 속성을 선별하고 각 속성별로 모자이크 플롯 분석, 3차원 그래프 분석, 토픽 분석 등 다양한 방법을 통해 위험요소를 찾는 연구가 진행되었다[1-6].

중도탈락을 예방하기 위하여 로지스틱 회귀분석과 다층 퍼셉트론 기법, CNN, 의사결정트리 등을 이용한 학습 데이터 분석을 통해 예측 모델을 생성하고 해당

모델을 평가하였다. 먼저 독립변수들을 추출하고 독립변수의 조합별로 생성된 모델의 성능평가를 실시하여 어떠한 독립변수의 조합이 우수한지를 연구하였다 [7-10].

이처럼 기존연구에서는 위험요소별로 중도탈락률에 어떠한 영향을 미치는지를 조사하였으나 위험요소간의 연관성을 고려하지 못하였다. 그리고 위험요소를 파악하여 이를 차단하는 것에 집중하였으며 중도탈락의 가능성을 예측하지는 못하였다. 또한 예측을 하더라도 예측을 위한 위험요소들이 매우 단순하며 이를 구현하는 방법이 제한되어 있다.

III. 문제정의

다수의 대학들은 학생의 효율적인 관리를 위해 고도화된 학생관리 시스템을 도입하여 운영한다. 특히 다양한 대학의 평가와 재정지원 사업의 평가에서 이러한 시스템의 운영은 필수적이다. 대학의 특성에 따라 목적은 다소 상이할 수 있지만 이 시스템의 공통적인 목적은 학생의 학습활동과 교수 활동에 관련된 다양한 데이터를 수집하고 분석하며 학습 및 진로와 관련된 여러 가지 서비스를 제공하는 것이다. 대학에 따라 최근에는 학생성장 데이터의 패턴 분석을 통해 대학생활 적응 정도를 파악하고 예상되는 문제를 조기에 발견하는 고도화된 서비스를 제공하기도 한다.

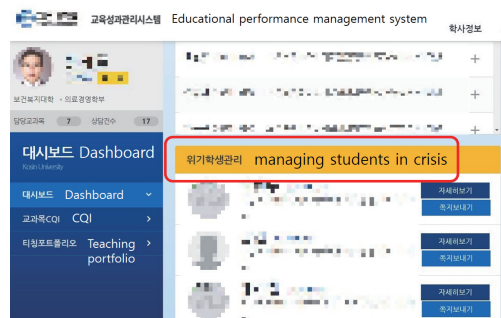


그림 1. 학생관리시스템의 위기학생 관리
Fig. 1 Management system for students at risk of dropout

지방에 위치한 k대학에서도 이러한 시스템을 운영하고 있는데 특히 학업중단 위기학생 관리를 위하여

다음과 같은 기능이 추가된 학생관리 시스템을 운영하고 있다. 먼저 학기를 시작하기 전에는 직전학기 성적을 기준으로 2.0 미만의 학생을, 학기를 시작 후에는 현재 시점으로부터 2주 전까지 결석 횟수가 특정 회를 넘은 학생을 학업중단 위기학생으로 판단하여 시스템에서 그림 1과 같이 교수에게 통보한다.

이런 방식으로 학업중단 위기학생을 판단하는 시스템의 문제점은 다음과 같다. 먼저 직전학기 성적이나 최근 출석 등을 포함한 다양한 학업중단 위험요소 간의 연관성을 배제한 단변수 분석을 통해 학업중단 위험요소를 파악하므로 학업중단 위기학생의 예측이 매우 부정확하다. 또한 출석상황 등의 위험요소는 학업중단 가능성의 예측이 아니라 이미 결과가 발생한 후의 징후이므로 선제 대응이 불가하다. 이처럼 대부분의 대학은 학업중단 가능성을 예측하지 못하고 학업중단 위험요소의 차단에 집중하고 있다.

본 논문에서는 머신러닝을 이용한 학업중단 위기학생 관리시스템을 설계한다. 이를 위하여 학업중단 위험요소 파악하고 학업중단 예측을 위해 머신러닝 방법을 사용하여 학업중단 위험요소를 독립변수로 다변수 분석을 실시한다. 또한 다양한 예측방법의 성능평가를 통해 최적화 방법을 도출하고 독립변수간의 연관성과 기여도를 실험을 통해 평가한다.




그림 2. 시스템 설계를 위한 연구 단계
Fig. 2 Research phases for system design

IV. 학업중단 위기학생 관리 시스템 설계

본 논문의 연구절차는 그림 2와 같다. 먼저 데이터 수집을 위하여 문헌과 데이터베이스에 저장되어 있는 데이터를 파악한다. 이후 학업중단 위험요소를 파악하여 독립변수로 선정하고 선정된 독립변수를 대상으로 데이터를 수집하고 결측치 제거 등의 데이터 정제를

수행한다. 그리고 각 독립변수별로 단변수 분석을 실시하여 어떠한 독립변수가 결과에 영향을 미치는지를 파악한다. 최종적으로 머신러닝을 이용한 모델을 오랜 지로 구현하고 성능평가를 실시하여 최적화 방법을 도출하고 독립변수간의 연관성과 기여도를 실험을 통해 평가한다.

4.1 데이터 수집

데이터 수집을 위하여 본 논문에서는 먼저 학업중단 위험요소를 파악하여 독립변수로 선정하였다. 독립변수의 선정 절차는 이론적 기반, 사전연구 및 경험적 발견에 근거하여 변수를 추가하는데 관련 연구에서 다루는 위험요소를 참고하여 대학의 데이터베이스에 저장되어 있는 데이터들 중에서 가장 연관성 있는 위험요소를 추출하여 독립변수로 선정하였다. 선정된 독립변수는 성별, 학과, 학년, 입학유형, 학사경고횟수, 휴학횟수, 주소, 누적성적, 직전학기성적, 상담횟수, D, F 교과목수 등 총 11개이다.

대상은 지방에 소재하는 중소형 대학인 k 대학의 2018년도부터 2020년도까지 3년간 재학 중인 학생의 데이터이다. 총 27,594개의 데이터를 수집하였고 먼저 주소데이터에서 구 데이터를 분리하고 결측 데이터를 제거하였다. 이후 입학유형 결측 데이터를 제거하고 직전학기 성적이 0점인 데이터(신입학, 휴학 등)를 제거하였다. 데이터 정제를 완료하여 수집한 데이터는 11개의 독립변수와 1개의 종속변수로 구성된 총 22,394개의 데이터이다.

표 1. 주요 변수별 탈락률 비교
Table 1. Comparison of dropout rates by major variables

	feature	attending	dropout	ratio
gender	male	9,209	525	5.39
	female	12,276	384	3.03
grade	1	3,122	222	6.64
	2	6,360	322	4.82
	3	5,522	297	5.10
	4	6,481	68	1.04
admission type	susi-haksaeng	2,156	65	2.93
	susi-gyogwa	11,334	399	3.40
	jungsi	6,260	370	5.58
	jeongwonoe	1,180	51	4.14
	pyeonib	555	24	4.15

4.2 데이터의 단변수 분석

11개의 독립변수가 각각 탈락률에 어떠한 영향을 미치는지 단변수 분석을 실시하였다. 각 독립변수별로 탈락률을 계산하고 이를 분석하였다. 표 1은 주요 독립변수에 대한 재학생과 제적생의 비율을 나타낸다. k대학의 전체 탈락률은 4.06%로서 여자보다 남자의 탈락률이 높았으며 입학후 대학부적응과 군입대 등으로 1, 3학년 때의 탈락률이 높게 나타났다. 또한 입학 유형에 따라 수시 학생부 종합직진학기전형의 탈락률이 상대적으로 낮게 나타났다.

표 2. 성적관련 변수별 탈락률 비교

Table 2. Comparison of dropout rates by grade-related variables

feature		attending	dropout	ratio
score (cumulative)	0~1.0 under	659	96	12.72
	1.0~2.0 under	466	161	25.68
	2.0~3.0 under	4,637	303	6.13
	3.0~4.0 under	13,048	290	2.17
	4.0 over	2,675	59	2.16
score (previous semester)	0~1.0 under	278	164	37.10
	1.0~2.0 under	900	175	16.28
	2.0~3.0 under	4,871	235	4.60
	3.0~4.0 under	11,232	252	2.19
	4.0 over	4,204	83	1.94
academic warning	0	20,500	759	3.57
	1	568	96	14.46
	2	275	35	11.29
	3 over	142	19	11.80
D, F subjects	0	20,455	762	3.59
	1	603	51	7.80
	2	205	42	17.00
	3 over	222	54	19.57

표 2는 성적과 관련된 독립변수에 대한 재학생과 제적생의 비율을 나타낸다. 누계성적의 경우 1.0~2.0사이의 학생의 탈락률이, 직진학기성적의 경우 0~1.0사이의 학생의 탈락률이 높게 나타났다. 학사경고의 경우 1회에서, D,F 과목수의 경우 6회 이상에서 탈락률이 높게 나타났다. 이처럼 단변수 분석을 실시하는 경우 각각 변수에 대하여 결과의 경향은 파악할 수 있으나 종합적인 판단에 의한 예측이 불가능하다.

앞장에서 k대학의 학업중단 위기학생 판단의 방법에 대하여 언급하였는데 직진학기 성적이 2.0미만인

학생이 대상인 것은 위의 결과에서 매우 적절하다 판단되지만 실제로 2.0~3.0미만의 학생 탈락율도 평균 탈락율보다 높으며 이러한 학생은 위기학생의 대상에 포함되지 않으므로 효율적인 관리가 어렵다.

본 논문에서는 학업중단 예측을 위해 머신러닝 방법을 사용하여 학업중단 위험요소를 독립변수로 다변수 분석을 실시한다. 또한 다양한 예측방법의 성능평가를 통해 최적화 방법 도출하고 독립변수간의 연관성과 기여도를 실험을 통해 평가한다.

4.3 머신러닝을 이용한 모델 생성 및 평가

머신러닝을 이용한 모델을 구현하고 성능평가를 실시하여 최적화 방법 도출하고 독립변수간의 연관성과 기여도를 실험을 통해 평가한다. 성능평가를 위한 독립변수 조합의 실험군을 표 3과 같이 구성하였다.

Case1은 독립변수 전체로 구성된 실험군으로서 이를 기준으로 독립변수의 삭제 조합으로 실험군을 구성한다. Case2, Case3, Case4는 단변수 분석에서 가장 영향을 미치는 누적성적과 직진학기성적이 성능에 어떠한 영향을 미치는지 파악하기 위한 실험군이다. Case5는 성적관련 독립변수와 다중공선성을 가지는 독립변수를 확인하기 위한 실험군이며 Case6은 성적을 제외한 다른 독립변수를 배제하여도 예측이 가능하지를 파악하기 위한 실험군이다.

표 3. 성능평가를 위한 실험군

Table 3. Experimental group for performance evaluation

dataset	number	explanation
Case1	11	All independent variables
Case2	10	Excluding cumulative grades
Case3	10	Excluding previous semester grades
Case4	9	Excluding cumulative grades and grades from the previous semester
Case5	9	Academic warning, excluding the number of DF courses
Case6	2	Only cumulative grades and grades from the previous semester are used
independent variables		Gender, department, grade, admission classification, academic warning, leave of absence, address, cumulative grades, grades from the previous semester, number of consultations, number of DF courses

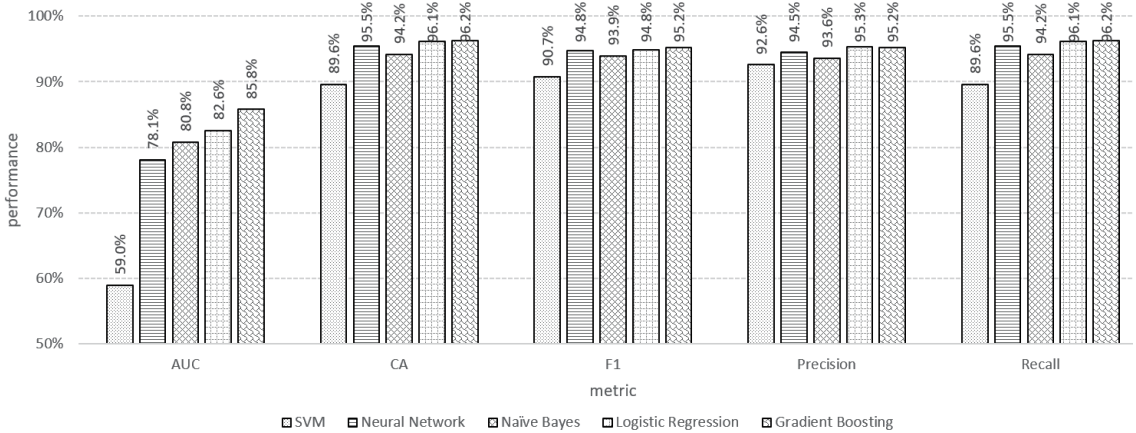


그림 3. 예측 방법별 성능평가 비교(Case1~Case6의 평균값)

Fig. 3 Comparison of performance evaluation among prediction methods(average value of Case1 ~ Case6)

성능평가를 수행하기 위하여 사용하는 예측 알고리즘은 지도학습 이진분류의 문제이므로 서포트벡터머신(Support Vector Machine), 신경망(Neural network), 나이브베이즈(Naive Bayes), 로지스틱회귀(Logistic Regression) 그리고 그래디언트 부스팅(Gradient Boosting) 방법을 사용하였다. 모델을 평가하기 위한 측정지표는 표 4와 같다. 데이터셋이 한쪽으로 매우 치우친 분포이므로 CA(Classification Accuracy) 등으로의 지표로는 정확한 성능을 평가하기 어려우므로 총 5개의 측정지표를 모두 사용하여 평가하였으며 학업중단 위기학생을 예측하는 이진분류이므로 AUC의 측정지표가 매우 유용하다.

표 4. 성능평가를 위한 평가지표
Table 4. Metrics for performance evaluation

metric	explanation
AUC	the predictive performance of binary classification based on the ROC curve
CA	the ratio of the number of correct answers to the total number of predictions, including both positive and negative
Precision	proportion of positives predicted by the classifier among those that actually have positive answers
Recall	percentage of positive predictions that are actually positive
F1	harmonic average index considering Precision and Recall

그림 3은 모든 실험군에 대한 예측 방법별 성능평가 비교이다. 6개의 모든 실험군에 대하여 5개의 예측 알고리즘을 구현하였고 이에 대한 5개의 측정지표별 6개의 실험군의 평균값을 계산하여 그래프로 나타내었다. 그림과 같이 모든 지표에서 그래디언트 부스팅 방법의 성능이 우수하였으며 서포트벡터머신의 성능이 가장 뒤쳐졌다. 이진분류의 성능을 잘 측정하는 AUC의 경우 다른 지표값보다 낮게 측정되었는데 이는 한쪽으로 매우 치우친 데이터 셋에서 Positive 값에 초점을 맞춘 다른 지표들과는 달리 Positive 값과 Negative 값을 동시에 고려하기 때문이다.

앞서 k대학에서는 학기 시작 전에 직전학기 2.0미만의 학생을 학업중단 위기학생으로 판단한다고 언급하였다. 이 방법의 성능을 평가하기 위하여 혼동행렬을 작성하고 각각의 지표를 계산하면 CA는 92.2%로 다른 방법에 비해 저조하지는 않지만 Precision, Recall, F1이 각각 22.3%, 37.3%, 28.0%로 매우 저조하여 학업중단 위기학생을 예측하고 효율적으로 관리하기에 부적합하다.

그림 4는 단변수 분석에서 탈락률 분포가 한쪽으로 치우친 누적성적과 직전학기성적이 예측 성능에 어떠한 영향을 미치는지를 실험하고 비교분석한 그래프이다. 이진분류를 가장 잘 측정하는 지표인 AUC에 대하여 각 예측 알고리즘의 성능을 표시하였다. 결과와 같이 전체 독립변수에서(Case1) 누적성적을 제외하거

나(Case2) 직전학기성적을 제외하여도(Case3) 성능에는 거의 차이가 없었다. 이는 두 독립변수가 매우 유사하며 하나를 제외하더라도 서로 보완적이기 때문에 영향이 없다는 것을 의미한다.




그림 4. 성적관련 독립변수의 AUC 성능평가 비교
Fig. 4 Comparison of AUC performance evaluation for credit-related independent variables

그림 5은 누적성적과 직전학기성적을 제외한 실험군에 대하여 AUC 예측 성능을 비교분석한 그래프이다. 결과와 같이 전체 독립변수에서(Case1) 누적성적과 직전학기성적을 모두 제외하면(Case4) 성능이 떨어지게 된다. 이는 두 독립변수가 매우 중요한 독립변수이며 성능에 많은 영향을 미친다는 것을 의미한다.




그림 5. 성적관련 독립변수 제외 AUC 성능평가 비교
Fig. 5 Comparison of AUC performance evaluation excluding grade-related independent variables

그림 6은 기타 독립변수에 대하여 AUC 예측 성능을 비교분석한 그래프이다. 결과와 같이 전체 독립변수에서(Case1) 누적성적과 직전학기성적을 모두 제외하거나(Case4) 누적성적과 직전학기성적을 남겨두고 다른 모든 독립변수를 제외하면(Case6) 성능이 떨어지게 된다. 특히 Case6처럼 오로지 성적만으로 탈락률을 예측하는 경우에는 매우 저조한 성능이 나타났다. 이는 성적으로 학업중단 위기학생을 판단하는 현재의 시스템이 정확하지 않다는 것을 의미한다. 따라서 탈락률을 결정하는 것은 성적뿐만 아니라 다양한

독립변수들도 서로 연관성이 있으며 결과에 많은 영향을 미친다는 것을 의미한다.

결론적으로 탈락률 예측시 성적은 매우 중요한 변수이며 직전학기성적이 유의미하게 좀더 영향을 미치는 것으로 나타났다. 또한 누적성적과 직전학기성적은 서로 연관되어 하나를 제외하더라도 크게 영향을 받지 않았으며 두개를 모두 제거하면 성능이 저하됨을 알 수 있었다. 기타 독립변수들도 매우 중요한 변수로서 기존 시스템에서 직전학기성적으로만 학업중단 위기학생을 예측하는 것은 부정확하다는 것을 알 수 있었다.




그림 6. 기타 독립변수의 AUC 성능평가 비교
Fig. 6 Comparison of AUC performance evaluation for other independent variables

V. 결론 및 향후 연구

본 논문에서는 머신러닝을 이용한 학업중단 위기학생 관리시스템을 설계하였다. 이를 위하여 학업중단 위험요소 파악하고 학업중단 예측을 위해 머신러닝 방법을 사용하여 학업중단 위험요소를 독립변수로 다변수 분석을 실시하였다. 실험결과 그라디언트 부스팅 방법이 매우 효율적이었으며 독립변수들이 결과에 어떠한 영향을 미치는지를 파악하여 독립변수의 기여도를 평가하였다. 향후 연구에서는 다양한 정량지표와 설문조사 결과를 독립변수로 추가하여 탈락률 예측의 정확도를 높이는 것이다.

References

[1] S. Hwang, D. Shin, J. Oh, Y. Lee, and J. Kim, "A Regression Analysis of Factors Affecting Dropout of College Students," *Journal of the Institute of*

- Internet, Broadcasting and Communication*, vol. 20, no. 4, Aug. 2020, pp. 187-193.
- [2] E. Lee and J. Lee, "A Exploratory Study on the Determinants Predicting Student Departure of Freshmen: Focusing on the Case of S University," *Journal of the Korea Contents Association*, vol. 21, no. 4, Apr. 2021, pp. 317-330.
- [3] J. Kim, "Analysis of dropout behavior and influencing factors of university students using big data analysis techniques," *Journal of the Korean Institute of Intelligent Systems*, vol. 31, no. 2, Apr. 2021, pp. 150-157.
- [4] D. Jung and J. Park, "Data Analysis of Dropouts of University Students Using Topic Modeling," *Journal of Korea Institute of Information and Communication Engineering*, vol. 25, no. 1, Jan. 2021, pp. 88-95.
- [5] J. Lim, "Education factors affecting the dropout intention of college students," *Journal of the Korea Entertainment Industry Association*, vol. 14, no. 3, Mar. 2020, pp. 105-115.
- [6] H. Kim, "Development and effectiveness analysis of dropout prevention programs for local college student," *Journal of Fisheries and Marine Sciences Education*, vol. 32, no. 3, Mar. 2020, pp. 823-833.
- [7] J. Lee, D. Kim, and J. Gil, "A Study on the Prediction Model for Student Dropout," *Annual Conference of the Korea Information Processing Society*, Seoul, Korea, May 2018.
- [8] C. Evandro, F. Baldoino, S. Almeida, A. Ferreira, and R. Joilson, "Evaluating the effectiveness of educational data mining techniques for early prediction of students' academic failure in introductory programming courses," *Journal of Computers in Human Behavior*, vol. 73, May. 2017, pp. 247-256.
- [9] G. Park and Y. Bae, "Performance Comparison of Machine Learning in the Various Kind of Prediction," *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 1, Jan. 2019, pp. 169-178.
- [10] M. Jo, "A Study on the History, Classification

and Development Direction of Artificial Intelligence," *Journal of the Korea Institute of Electronic Communication Sciences*, vol. 16, no. 2, Mar. 2021, pp. 307-312.

저자 소개



반재훈(Chae-Hoon Ban)

2006년 부산대학교 대학원 컴퓨터공학과 졸업(공학박사)

2008년 ~ 현재 고신대학교 IT경영학과 교수

※관심분야 : 인터넷응용, 모바일, 빅데이터



김동현(Dong-Hyun Kim)

2003년 부산대학교 대학원 컴퓨터공학과 졸업(공학박사)

2004년 ~ 동서대학교 컴퓨터공학부 교수

※관심분야 : 데이터베이스, 공간 데이터베이스, GIS, 센서데이터베이스



하종수(Jong-Soo Ha)

2013년 일본 큐슈대학교 예술공학 박사

2002년 ~ 경남정보대학교 방송영상과 부교수

※관심분야 : 인터넷응용, 입체영상, VR, MR

