

# 가상현실 기반 건설안전교육에서 개인특성이 학습성과에 미치는 영향 - 머신러닝과 SHAP을 활용하여 -

최다정<sup>1</sup> · 구충완<sup>2\*</sup>

<sup>1</sup>인천대학교 일반대학원 건축학과 석사과정 · <sup>2</sup>인천대학교 도시건축학부 부교수

## Impact of personal characteristics on learning performance in virtual reality-based construction safety training - Using machine learning and SHAP -

Choi, Dajeong<sup>1</sup>, Koo, Choongwan<sup>2\*</sup>

<sup>1</sup>Graduate Student, Department of Architectural Engineering, Graduate School, Incheon National University

<sup>2</sup>Associate Professor, Division of Architecture & Urban Design, Incheon National University

**Abstract :** To address the high accident rate in the construction industry, there is a growing interest in implementing virtual reality (VR)-based construction safety training. However, existing training approaches often failed to consider learners' individual characteristics, resulting in inadequate training for some individuals. This study aimed to investigate the impact of personal characteristics on learning performance in VR-based construction safety training using machine learning and SHAP (SHAPley Additional exPlanations). This study revealed that age exerted the greatest influence on learning performance, while work experience had the least impact. Furthermore, age exhibited a negative relationship with learning performance, indicating that the introduction of VR-based construction safety training can be effective for younger individuals. On the other hand, academic degree, qualifications, and work experience exhibited a positive relationship. To enhance learning performance for individuals with lower academic degree, it is necessary to provide content that is easier to understand. The lower qualifications and work experience have minimal impact on learning performance, so it is important to consider other learners' characteristics so as to provide appropriate educational content. This study confirmed that personal characteristics can significantly affect learning performance in VR-based construction safety training, highlighting the potential for leveraging these findings to provide effective safety training for construction workers.

**Keywords :** Construction safety training, Virtual reality, Learning performance, Personal characteristics, Machine learning & SHAP

## 1. 서론

### 1.1 연구의 배경 및 목적

최근 10년간 건설업의 재해자 수와 사망자 수가 증가하고 있다(Ministry of Employment and Labor, 2020). 2022년 기준, 건설업의 재해자 수와 사망자 수는 각각 27,432명, 402명으로서, 전체 산업 중 가장 많은 것으로 나타났다(Korea Occupational Safety and Health Agency, 2022).

이러한 건설업의 높은 재해율을 감소시키기 위해서는 적절한 안전관리를 수행할 필요가 있다. Heinrich의 도미노 이론에 근거하여(Heinrich, 1941), 불안정한 상태를 해소함으로써 안전사고를 예방하기 위한 계획을 수립하고 있다. 이러한 안전관리 계획은 '건설근로자가 위험을 인지했다'라는 가정하에 수립되고 있는데, Haslam et al. (2005)에 따르면, 실제 건설업에서 발생하는 사고의 42% 이상은 '불충분한 위험 인지' 또는 '부적절한 위험평가'와 같은 건설근로자의 불안정한 행동과 연계된 것으로 나타났다.

이러한 배경에서, 국내에서는 총 6가지의 법적 의무 건설 안전교육제도를 통해, 건설현장의 불안정한 상태와 건설근로자의 불안정한 행동에 대한 교육을 시행하고 있다. 특히, 산업안전보건법에 따라, 건설업 일용근로자는 건설업기초 안전보건교육을 의무적으로 이수해야 한다. 그런데, 강의식

\* **Corresponding author:** Koo, Choongwan Division of Architecture & Urban Design, Incheon National University 618, 28 B/D, 119 Academy-ro, Yeonsu-gu, Incheon, Korea

**E-mail:** cwkoo@inu.ac.kr

**Received** June 15, 2023: **revised** -

**accepted** September 18, 2023

교육에 따른 수동적 학습방식으로 인해, 학습성과 저하가 발생할 수 있다(Shin et al., 2015; Park, 2017; Lee, 2020). 이를 방지하고자 KOSHA에서는 가상현실(virtual reality; VR) 기반 건설안전교육 콘텐츠를 제공하고 있다.

KOSHA에서 제공하는 VR 기반 건설안전교육 콘텐츠는 주요 안전사고 유형과 공사 특성을 고려하여 개발되었지만, 학습자의 개인특성에 따른 차이를 고려할 수 없다는 한계가 있다. 이에 따라, 학습자의 판단에 따라 안전사고 발생 여부가 결정될 수 있는 방식이 아닌, 콘텐츠 제작의도에 따라 교육이 진행되는 일방향적 교육방식으로 인해, 일부 학습자는 개인특성(연령, 자격, 학력, 경력 등)의 한계에 따라 효과적인 안전교육을 받지 못하는 경우가 발생할 수 있다.

따라서 본 연구에서는 머신러닝과 SHAP (SHAPley Additional exPlanations)을 활용하여, VR 기반 건설안전교육에서 개인특성이 학습성과에 미치는 영향을 분석하고자 하였다. 이를 통해, 건설안전교육에 있어 개인특성을 고려할 수 있는 방향을 모색함으로써, VR 기반 건설안전교육의 학습성과 향상에 기여하고자 한다.

### 1.2 연구의 범위 및 방법

본 연구에서는 VR 기반 건설안전교육의 학습성과에 영향을 미치는 건설근로자의 개인특성을 분석하였다(Fig. 1). 본 연구의 실험은 건설업기초안전보건교육에 참여한 건설근로자를 대상으로 수행하였다. 실험에 참여한 학습자에게 '쌍줄 비계 추락예방을 위한 VR 기반 안전교육 콘텐츠'를 체험하도록 하였고, 체험이 종료된 후 학습성과 평가 시험과 학습자 개인특성에 대한 설문을 수행하도록 하였다.

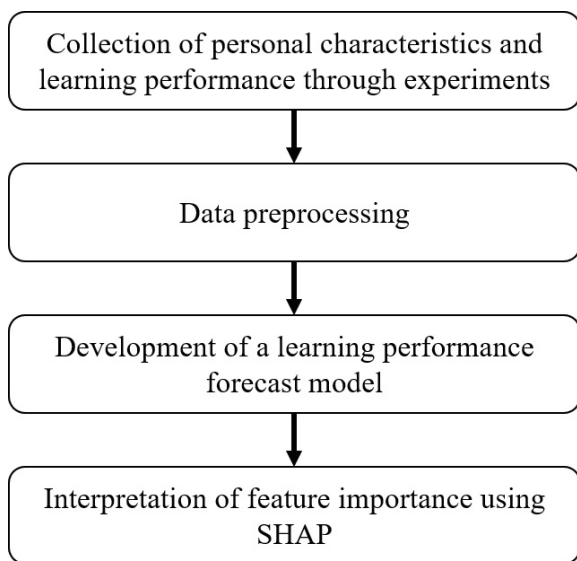


Fig. 1. Research Framework

상기의 수집된 데이터를 토대로 하여, 머신러닝(machine learning) 알고리즘을 적용함으로써, 건설근로자의 학습성과를 예측하기 위한 모델을 개발하였다. 즉, 학습자의 개인특성을 독립변수로 하고, 학습성과를 종속변수로 하는 예측 모델을 개발하였다. 또한, VR 기반 건설안전교육에서 개인특성이 학습성과에 미치는 영향을 분석하기 위하여, SHAP 방법론을 채택하였다. SHAP 방법론에서는, 각각의 독립변수(특성요인)가 종속변수에 미치는 영향을 shapley value로 산출함으로써 독립변수별(특성요인별) 중요도를 제시한다. 더불어, 산점도를 통해 독립변수별(특성요인별) shapley value의 분포를 제시한다. 본 연구에서는 머신러닝과 SHAP을 활용하여, 개인특성에 따른 학습성과 예측모델을 구축하고, 예측결과에 대한 유의미한 해석을 통해 개인특성이 학습성과에 미치는 영향을 상세하게 분석하고자 한다.

## 2. 이론적 고찰

### 2.1 건설안전교육의 학습성과에 영향을 미치는 개인 특성

기존 연구에서는, 건설안전교육을 통해 향상시키고자 하는 안전 준수(safety compliance) 관점에서, 건설안전교육의 학습성과에 영향을 미치는 개인특성에 대한 분석을 수행하였다(Feng & Wu, 2015; Loosemore & Malouf, 2019; McCabe et al., 2008).

Meng and Chan (2020)은 건설근로자의 안전 의식(safety consciousness)과 안전 시민행동(safety citizenship behavior)에 영향을 미치는 개인특성을 분석하였다. ANOVA 분석 결과, 학력, 경력, 성별이 유의미한 영향을 미치는 것으로 나타났다. Liu et al. (2021)은 건설근로자의 개인특성이 위험 지각 및 대응 행동(risk perception and coping behavior)에 미치는 영향을 분석하였다. ANOVA와 독립표본 t-test 분석 결과, 연령, 자격, 학력, 성별이 유의미한 영향을 미치는 것으로 나타났다. Yu et al. (2022)은 VR 기반 건설안전교육에서 학습자의 5가지 개인특성(즉, 연령, 학력, 경력, 성별, 직무)가 학습 효과(learning effectiveness)에 미치는 영향을 분석하였다. MANOVA (Multivariate Analysis of Variance) 분석 결과, 직무(예: 거푸집, 철골, 장비, 배관, 기타) 특성만 학습성과에 영향을 미치는 것으로 나타났다.

상기의 선행연구에서는, ANOVA, t-test와 같은 통계분석 기법을 활용하여 건설안전교육에서 학습자의 개인특성이 학습성과에 미치는 영향을 분석했다. 이러한 통계분석 기법은 개인특성에 따른 학습성과의 차이를 규명할 수 있으나, 개인특성과 관련된 학습성과의 경향성 및 개인특성이 학습

성장에 미치는 영향 정도를 충분히 파악할 수 없다는 한계를 갖고 있다. 이러한 배경에서, 전통적인 통계분석 기법이 아닌 머신러닝 방법론을 활용함으로써, 개인특성에 따른 학습성장을 예측하고 개인특성과 학습성과 간의 비선형적인 관계에 대한 다각적인 분석을 수행할 수 있다. 본 연구에서는 머신러닝을 활용하여, VR 기반 건설안전교육의 학습성장에 영향을 미치는 개인특성 변수를 파악함과 동시에, 개인특성이 미치는 영향수준을 다각적으로 분석함으로써, 학습자에게 더욱 적절한 안전교육을 제공할 수 있는 기반을 마련하고자 한다.

## 2.2 머신러닝 알고리즘

머신러닝은 입력된 데이터에서 패턴(classification or regression)을 학습하고, 이를 기반으로 학습되지 않은 데이터의 패턴을 추론하는 알고리즘을 의미한다(Bzdok et al., 2017). 머신러닝에는 다양한 알고리즘이 존재하나, 본 연구에서는 건설근로자의 개인특성을 활용한 학습성과 예측을 위해 5가지 알고리즘(즉, Ridge Regression (Ridge), Random Forest (RF) Regression, Extreme Gradient Boosting (XGBoost) Regression, Support Vector Regression (SVR), Multi-Layer Perceptron (MLP) Regression)을 채택하였다.

- Ridge: 선형회귀 모델에  $L_2$ -penalty term을 추가하여, 정규화(regularization)를 진행한 알고리즘이다(Hoerl & Kennard, 1970). 회귀계수를 최소화함으로써, 종속 변수에 미치는 영향이 미비한 독립변수들의 계수 값을 작게 할 수 있고, 모델의 분산을 유의미하게 줄일 수 있어, 기존 선형회귀모델의 과적합 문제를 해결할 수 있다(Thevaraja et al., 2019).
- RF: 여러 개의 의사결정나무(Decision Tree)를 사용하는 앙상블 모델로서, 최종 예측값 결정 시, 다수의 의사결정나무의 예측결과에 대한 평균값을 최종 예측값으로 결정함으로써, 기존 의사결정나무 대비 일반화 성능이 뛰어난 특성이 있다(Segal, 2004). 독립변수 간 상관성이 있는 데이터들에 대한 분석이 용이한 반면, 여러 개의 의사결정나무로부터 예측값을 도출하기 때문에, 예측결과를 해석하기 어렵다는 단점이 있다(Breiman, 2001).
- XGBoost: Gradient Boosting 모델에 병렬 처리가 가능하도록 구성한 모델로서, Gradient Boosting 모델 대비 학습 속도가 빠르고, RF와 유사하게 여러 개의 의사결정나무로부터 예측값을 결정하는 특성이 있다. 또한, 과적합 방지를 위한 파라미터가 추가되어, 일반화 성능이 뛰어난 특성이 있다(Chen & Guestrin, 2016).
- SVR: 기존 SVM 모델에  $\epsilon$ -insensitive loss function을 도

입한 모델로서, 기존 SVM은 초평면과 마진을 최대화하도록 학습하는 반면, SVR은  $\epsilon$ (오차 허용률) 이내에 예측값을 위치하도록 하여, 노이즈의 영향을 최소화할 수 있다(Smola & Schölkopf, 2004). 커널함수와 정규화를 통해, 비선형 데이터에 대한 분석이 가능하고, 각 집단에 대한 오류를 최소화하는 함수를 사용함으로써, 비교적 정확도가 높은 특성이 있다(Cortes & Vapnik, 1995).

- MLP: 한 개 이상의 퍼셉트론(perceptron)이 은닉층으로 구성된 순방향 인공신경망으로서, 기존의 알고리즘과는 달리 데이터 분포에 대한 사전 가정을 하지 않는 특성이 있다. 또한, 입력층과 출력층 사이에 하나 이상의 은닉층이 존재하여, 비선형적 데이터에 대한 학습이 가능한 특성이 있다(Murtagh, 1991).

## 2.3 SHAP 분석

머신러닝 모델은 변수 간의 관계를 해석하고 이를 바탕으로 입력값에 대응하는 예측값을 제공하지만, 사용자가 입력값과 예측값 간의 인과관계를 파악할 수 없기 때문에, 모델을 이해하고 해석하는데 한계가 있다. 이러한 문제를 해결하기 위해, 해석가능한 인공지능 기법(Interpretable Artificial Intelligence)이 발전되어 왔고, 머신러닝 모델을 해석할 수 있게 되었다. 예측모델에 대한 통찰력을 얻어 의사결정에 도움을 줄 수 있는 해석가능한 인공지능 기법의 대표적인 방법론으로는, LIME (Local Interpretable Model-agnostic Explanation), SHAP (SHapley Additive exPlanations) 등이 있는데, 본 연구에서는 적용성이 높고, 대조 설명이 가능한 SHAP을 채택하였다.

SHAP은 협력게임이론(coalitional game theory)을 바탕으로, 각 특성값의 기여도를 shapley value로 산출한다. Shapley value는 Shapley (1953)에 의해 처음 제안되었고, Lundberg and Lee (2017)은 머신러닝 모델에 대해 shapley value를 계산할 수 있는 SHAP을 제안하여, 머신러닝 모델을 해석하는 데에 사용되고 있다. SHAP은 특성 간의 의존도를 고려할 뿐만 아니라, 음의 영향력을 반영하여 예측에 영향을 미치는 특성별 수준을 제시하므로, 특성별 정확한 영향력을 파악할 수 있다. 또한, 특성이 예측에 양(+) 또는 음(-)의 영향을 미쳤는지에 대해 제시하므로, 개별 특성의 영향에 대한 보다 자세한 분석이 가능하다. SHAP을 활용할 경우, 각 학습자의 개인특성이 학습성과 예측값에 미치는 영향력 수준을 파악할 수 있고, 이를 통해 개인특성이 학습성장에 미치는 영향을 상세하게 분석할 수 있다.

SHAP의 전역적 중요도(global importance)는 각 특성의 shapley value의 절댓값 평균으로 구할 수 있다. 다만, 전역적 중요도를 통해 모델에서 특성의 중요도는 알 수 있으나,



특성이 미치는 영향의 방향성을 알 수 없다. 각 특성과 학습성과 간 관계를 면밀하게 살펴보고자, 국지적 중요도(local importance)는 SHAP의 산점도를 통해 확인할 수 있다. 산점도에서의 y축은 특성을, x축은 각 값의 shapley value를 의미한다. 즉, 점이 x축으로부터 멀리 위치할수록, 해당 특성이 예측에 많은 영향을 미치는 것으로 해석할 수 있다. x축을 기준으로 우측은 양(+)의 기여도, 좌측은 음(-)의 기여도를 나타낸다. 점의 색상은 특성의 값을 의미하며, 붉을수록 높은 값을, 푸를수록 낮은 값을 의미한다. 즉, 붉은 점이 x축의 우측에 위치할 때, 점이 위치한 y축의 특성은 학습성과 양의 관계를 갖는 것으로 해석할 수 있다.

### 3. 데이터 수집 및 모델 개발

#### 3.1 데이터 수집

본 연구에서는, VR 기반 건설안전교육의 학습성과를 예측하기 위한 모델을 개발하고, 이를 토대로 개인특성이 학습성과에 미치는 영향을 분석하고자 실험을 수행하였다. 이러한 실험은 건설업기초안전보건교육의 '작업별 위험요인' 과목을 대체하여 진행되었고, 총 50분에 걸쳐 수행되었다.

본 연구에서는, 학습자(실험참가자)의 지식 차이가 학습성과에 미치는 영향을 제거하기 위하여, VR 기반 건설안전교육을 수행하기에 앞서, '쌍줄비계 추락 예방'에 대한 강의 교육을 수행하였다. 그 이후, 학습자(실험참가자)는 HMD 기기의 조작법에 대해 숙지하고, HMD 기기를 착용하여 '쌍줄비계 추락 예방에 대한 몰입형 VR 기반 건설안전교육 콘텐츠'를 체험하였다. VR 콘텐츠 체험 중, 학습자(실험참가자)는 가상의 쌍줄비계 작업 중 2개의 개인보호구와 2개의 작업환경에 대한 위험요인에 노출되며, 노출된 위험요인에 대한 학습자(실험참가자)의 적절한 조치 여부에 따라 사고 발생

여부가 결정된다. 사고 체험이 종료된 후, 학습자(실험참가자)는 앞서 체험한 각 위험요인에 대한 착용 실습 및 퀴즈 풀이를 진행하였다(Fig. 2).

VR 교육을 마친 학습자(실험참가자)는 학습성과 평가를 위한 시험과 개인특성 수집을 위한 설문문에 응답하였다. 첫째, CAMIL (Cognitive & Affective Model of Immersive Learning) 이론에 기반하여 기개발된 평가도구를 활용하여, 학습자(실험참가자)의 학습성과를 평가하고자 하였다. 평가도구의 36개 문항 중, 지식 영역에 대한 25개 문항을 대상으로 학습성과를 평가하였으며, 선다형 또는 서술형으로 출제된 문항의 정답 여부에 따라 1~5 범위의 점수로 환산하였다. 둘째, 학습성과에 영향을 미치는 개인특성에 대한 데이터를 수집하고자 설문을 수행하였다(Park, H., & Koo, C., 2022). 2.1절에서 선행연구 고찰을 통해 건설안전교육의 학습성과에 영향을 미치는 개인특성을 확인하였다. 특히, 연령, 자격, 학력, 경력, 성별, 직무 등 개인특성에 따라 학습성과에 유의미한 차이가 나타나는 것을 확인하였다. 이러한 특성에 대한 설문을 수행하였으며, 이렇게 수집된 개인특성은 머신러닝 기반 학습성과 예측 모델 개발 시, 독립변수로 활용하고자 하였다.

#### 3.2 데이터 전처리

본 연구에서는 머신러닝 기반 예측모델을 개발함에 있어, 학습자(실험참가자)의 학습성과를 종속변수로서 활용하였고, 학습자(실험참가자)의 개인특성을 독립변수로서 활용하였다. 여기서, 학습자(실험참가자)의 성비가 불균형하고(남:여=93:7), 경력이 있는 경우에는 보통인부로 근무했기 때문에, 성별과 직무를 제외한 연령(age), 자격(qualification), 학력(academic degree), 경력(work experience)을 독립변수로 활용하였다(Table 1). 이러한 개인특성 중, 연령은 설문 시나이를 기재하도록 하여, 그 값을 그대로 입력값으로 활용할 수 있었다. 반면, 자격, 학력, 경력은 명목형 척도로 수집했기 때문에, 이를 수치로 환산하였다. 수치 환산에는 건설기술사 등급을 활용했으며, <Table 2>는 개인특성에 대한 수치 환산 기준을 제시하고 있다. 한편, 변환된 독립변수에 대하여, Min/Max scaler를 적용함으로써, 0과 1 사이의 값으로 변환 후 모델학습을 진행하였고, 이를 통해 독립변수 값의 크기에 따른 편향이 발생하는 것을 방지하고자 하였다.

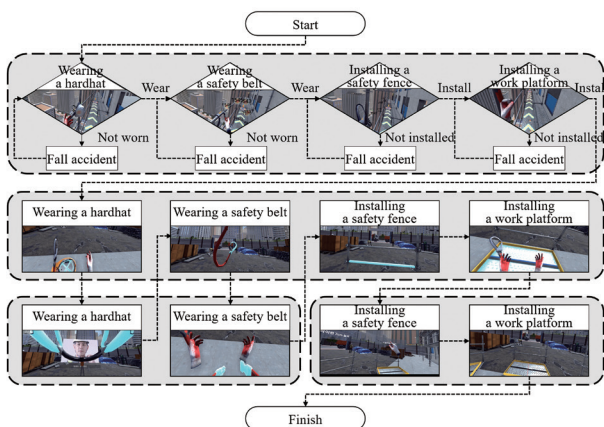


Fig. 2. Flowchart of 'VR-based training for fall prevention on scaffold'

Table 1. A summary of participant's personal characteristics

Classification		Number
Age	< 20 years old	3
	20 - 29 years old	8
	30 - 39 years old	8
	40 - 49 years old	3
	50 - 59 years old	4
	≥ 60 years old	4
Qualification	None	23
	Craftsman	5
	Industrial engineer	2
	Engineer / Master craftsman	0
	Professional engineer / Architect	0
Academic degree	Less than high school graduate	4
	High school graduate	17
	Associate degree	3
	More than bachelor degree	6
Work experience	< 6 months	22
	6 months~1 year	2
	1 year~2 years	3
	2 years~3 years	0
	3 years~4 years	0
	4 years~5 years	0
	> 5 years	3

Table 2. Scoring criteria for personal characteristics

Personal characteristics	Answer type	Score	Scoring criteria
Age	Self-recorded input	Input value	-
Qualification	None	0	Refer to the grading table for the construction technology qualification index
	Craftsman	15	
	Industrial engineer	20	
	Engineer / Master craftsman	30	
	Professional engineer / Architect	40	
Academic degree	Less than high school graduate (Non-major)	10	Refer to the grading table for the construction technology education index
	High school graduate	15	
	Associate degree	18.5	
	More than bachelor degree	20	
Work experience	< 1 years	0	Refer to the grading table for the construction technology experience index / conversion formula → (log N/log40) x 100 x 0.4 ※ N = years of experience
	1 - 2 years	4.40	
	2 - 3 years	9.94	
	3 - 4 years	13.58	
	4 - 5 years	16.31	
	...	...	
≥ 40 years	40		

### 3.3 개인특성 기반 학습성과 예측모델 개발 및 평가

본 연구에서는 학습자(실험참가자)의 개인특성이 VR 기반 건설안전교육의 학습성과에 미치는 영향요인을 도출하고, 그 영향 수준을 분석하고자 하였다. 이를 위해, 5가지 머신러닝 알고리즘을 채택하여, 학습성과 예측모델을 개발했으며, GridSearchCV를 통해 각 알고리즘의 최적 매개변수(hyper-parameters)를 찾아, 높은 예측성능을 확보하고자 하였다. <Table 3>은 예측모델에 적용한 최적 매개변수이다.

한편, 예측모델 개발에 활용된 표본의 수가 30개로서 충분하지 않기 때문에, 분할된 학습데이터의 특성으로 인해 편향이 발생할 수 있다. 이러한 잠재적인 문제를 방지하기 위하여, LOOCV (Leave-One-Out Cross-Validation)을 적용해 예측모델의 성능을 검증하였다. LOOCV는 n개의 데이터 중 한 개의 데이터를 검증데이터로 활용하고, 나머지 n-1개의 데이터를 학습데이터로 활용해 예측모델을 구축하고 검증하는 방식이다. 이에 따라, n번의 학습을 진행하기 때문에, 무작위성의 오류가 발생하지 않고, 예측모델의 성능은 n번의 예측결과에 대한 평균값으로 산출된다.

학습성과 예측모델의 성능 평가를 위해, 평균절대오차(Mean Absolute Error; MAE)와 평균제곱오차(Mean Squared Error; MSE)를 활용하였다. 평균절대오차(MAE)는 실제값과 예측값의 차이, 즉 오차의 절대값에 대한 평균값으로 산출된다. 이러한 평균절대오차(MAE)는 예측모델의 성능을 직관적으로 비교할 수 있으나, 이상치(outlier)에 따른 예측성능의 변화에 민감하지 않다. 이에 따라, 이상치에 따른 예측성능의 변화를 상대적으로 민감하게 평가할 수 있는

Table 3. Hyperparameters by machine learning algorithm

Model	Hyperparameter
Ridge	- alpha: 1
RF (Random Forest)	- max_depth: 50 - max_features: sqrt - min_samples_leaf: 2 - min_samples_split: 8 - n_estimators: 100
XGBoost (eXtreme Gradient Boosting)	- learning_rate: 0.07 - max_depth: 3 - min_child_weight: 3 - gamma: 0 - subsample: 0.8 - colsample_bytree: 0.7 - reg_alpha: 1
SVR (Support Vector Regression)	- kernel: sigmoid - C: 10 - gamma: auto
MLP (Multi-Layer Perceptron)	- hidden_layer_sizes: (100, 100) - activation = logistic - alpha = 0.05 - learning_rate = constant - solver = lbfgs - max_iter = 500

평균제곱오차(MSE)를 함께 활용하는 것이 타당하다. 평균 제곱오차(MSE)는 오차의 제곱값에 대한 평균값으로 산출된다.

## 4. 분석결과

### 4.1 학습성과 예측모델의 성능 평가

5가지 예측모델의 성능을 비교한 결과, SVR, RF, Ridge, MLP, XGBoost 순으로 우수한 것으로 나타났다<Table 4>. 특히, 가장 우수한 성능을 가진 SVR의 경우, MAE가 0.237으로 산출되어 실제 값과의 차이가 가장 작을 뿐만 아니라, MSE가 다른 모델 대비 가장 작은 값으로 산출되어 상대적으로 안정적인 예측성능을 나타내는 것을 확인할 수 있었다. 예를 들어, 학습자(실험참가자)의 개인특성을 활용하여 학습성고를 예측했을 때, 학습성고의 실제값과의 차이가 0.237점(5점 만점)으로 매우 작은 것을 확인할 수 있었다.

Table 4. Comparison of forecast performance by machine learning algorithm

Machine learning algorithm	MAE (Mean Absolute Error)	MSE (Mean Squared Error)
Ridge	0.257	0.103
RF (Random Forest)	0.256	0.113
XGBoost (eXtreme Gradient Boosting)	0.264	0.115
SVR (Support Vector Regression)	0.237	0.082
MLP (Multi-Layer Perceptron)	0.261	0.103

### 4.2 SHAP를 활용한 학습성과 영향요인 분석

본 연구에서는 SHAP를 활용하여 학습성고에 영향을 미치는 개인특성의 중요도를 산출하였다<Table 5, Fig. 3, Figs. A1-A4 in Appendix>. SVR을 제외한 모든 알고리즘에서, 연령, 학력, 자격, 경력순으로 학습성고에 영향을 미치는 것으

Table 5. Comparison of feature importance by machine learning algorithm

No	Ridge		RF (Random Forest)		XGBoost (eXtreme Gradient Boosting)		SVR (Support Vector Regression)		MLP (Multi-Layer Perceptron)	
	Feature	Weight	Feature	Weight	Feature	Weight	Feature	Weight	Feature	Weight
1	Age	0.147637	Age	0.166809	Age	0.180372	Age	0.172429	Age	0.165209
2	Academic Degree	0.0847	Academic Degree	0.076116	Academic Degree	0.083455	Qualification	0.09209	Academic Degree	0.093269
3	Qualification	0.080302	Qualification	0.062827	Qualification	0.009522	Academic Degree	0.086486	Qualification	0.084981
4	Work Experience	0.026013	Work Experience	0.00376	Work Experience	0.000423	Work Experience	0.015756	Work Experience	0.029463

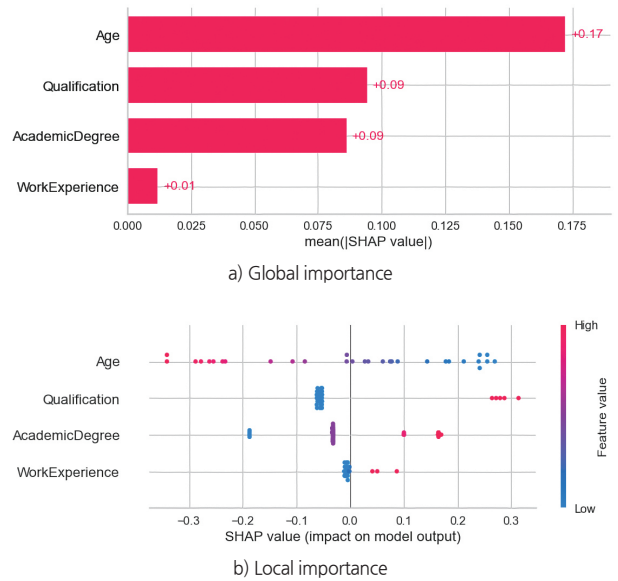


Fig. 3. SHAP value of SVR model

로 나타났다. SVR 모델의 경우, 연령, 자격, 학력, 경력순으로 학습성고에 영향을 미치는 것으로 나타났으나, 자격과 학력의 shapley value 값의 차이가 0.006으로서, 그 영향의 차이가 매우 작은 것을 확인할 수 있었다. 이러한 배경에서, 학습자(실험참가자)의 개인특성이 학습성고에 미치는 영향을 상세히 분석하기 위하여, 예측모델의 성능이 가장 우수한 SVR 모델의 Local Shapley Value를 확인하였다.

<Fig. 3b>에서 제시하는 국지적 중요도(local importance)는 SVR 모델의 Local Shapley Value를 도출한 결과이다. 다음과 같이, 연령, 자격, 학력, 경력 관점에서, 학습성고에 영향을 미치는 개인특성을 구체적으로 살펴보고자 하였다.

- 연령: 연령이 높은 붉은 점이 X축의 0을 기준으로 음(-)의 방향에 분포되어 있고, 전반적으로 고른 분포를 보이고 있어, 연령과 학습성고는 음의 상관관계를 갖는 것을 알 수 있었다. 즉, 연령이 높을수록 VR 기반 건설안전교육의 학습성고가 낮게 나타나는 것을 확인하였다.

- 자격: 자격이 높은 붉은 점이 양(+)의 방향에 분포되어 있고, 0.3 부근에 집중적으로 분포되어 있어, 학습성도에 미치는 영향수준이 큰 것으로 알 수 있었다. 반면, 자격이 낮은 파란 점이 음(-)의 방향에 분포되어 있고, -0.05 부근에 집중적으로 분포되어 있어, 자격이 높은 경우에 비해 학습성도에 미치는 영향수준이 낮은 것을 알 수 있었다. 즉, 자격과 학습성도는 양의 상관관계를 갖고 있으며, 자격이 없는 경우보다는 자격이 있는 경우에, 학습성도에 강한 영향을 미치는 것으로 해석할 수 있다.
- 학력: 학력이 높은 붉은 점이 양(+)의 방향에 분포되어 있고, 상대적으로 고른 분포를 보이고 있어, 학력과 학습성도는 양의 상관관계를 갖는 것을 알 수 있었다. 즉, 학력이 높을수록 VR 기반 건설안전교육의 학습성도가 높게 나타나는 것을 확인하였다.
- 경력: 경력이 높은 붉은 점이 양(+)의 방향에 분포되어 있어, 경력과 학습성도는 양의 상관관계를 갖는 것을 알 수 있었다. 다만, 파란 점은 0 부근에 분포되어 있어, 경력이 낮은 경우 학습성도에 미치는 영향이 거의 없는 것으로 나타났다.

## 5. 결론

본 연구에서는 VR 기반 건설안전교육에서 개인특성이 학습성도에 미치는 영향을 분석하고자 하였다. 우선, 머신러닝을 활용하여 학습성도 예측모델을 개발하였고, 이에 대한 SHAP 분석을 수행함으로써, 학습자(실험참가자)의 학습성도에 영향을 미치는 개인특성을 상세히 분석하였다.

전역적 중요도(global importance)를 살펴봤을 때, 연령이 학습성도에 가장 많은 영향을 미칠 수 있는 반면, 경력은 학습성도에 영향을 거의 미치지 않는 것으로 나타났다. 또한, XGBoost를 제외한 모든 알고리즘에서 학력과 자격은 유사한 영향수준을 갖는 것으로 나타났다.

국지적 중요도(local importance)를 살펴봤을 때, 연령은 학습성도와 음(-)의 상관관계를 갖는 것으로 나타났다. 이는 연령이 낮을수록 학습성도가 높은 것으로, 낮은 연령대에는 VR 기반 건설안전교육을 제공하는 것이 효과적일 수 있음을 시사한다. 연령대가 높을수록 VR 기반 건설안전교육에서의 학습성도가 낮게 예측되었으나, 이러한 결과는 가상현실에서의 학습성도는 연령과 무관하다고 주장한 Dobrowolski et al. (2021)의 이론과 차이가 있다. 이러한 차이는 연령에 따른 학습 콘텐츠 선호도 또는 인지 능력 저하에 의해 나타날 수 있으므로, 고연령의 학습자에게 적절한 안전교육 제공을 위한 추가적인 연구가 필요할 것으로 판단된다.

반면, 자격, 학력, 경력은 학습성도와 양(+)의 상관관계를

갖는 것으로 나타났다. 첫째, 자격의 경우, 자격이 있을 때 학습성도가 높게 예측되어, 자격이 있는 학습자에게 VR 기반 건설안전교육을 제공하는 것이 효과적일 수 있음을 시사한다. 자격이 없는 경우에는 상대적으로 학습성도가 낮게 예측되는 경향이 있으나, 그 영향이 매우 작은 것으로 나타나, 자격이 없는 학습자의 경우, 자격 외의 요인에 의해 학습성도가 영향을 받을 가능성이 높으므로, 그 외의 요인에 가중을 두어 학습자의 특성을 파악하고, 적절한 교육 콘텐츠를 제공할 필요가 있다. 둘째, 학력의 경우, 학력이 낮을수록 낮은 학습성도를 예측하는 것을 의미하므로, 동일한 교육 콘텐츠를 학습하게 했을 때, 학력이 높은 학습자에 비해 학력이 낮은 학습자는 충분한 학습효과를 보이지 못할 것으로 해석할 수 있다. 이러한 분석 결과를 통해 더욱 간단하고 이해하기 쉬운 콘텐츠를 개발함으로써, 학습자에게 적절한 안전교육을 제공하고, 학습성도를 향상시킬 필요가 있다. 셋째, 경력의 경우, 경력이 학습성도에 미치는 영향이 작고, 특히, 경력이 낮은 학습자의 경우, 경력이 미치는 영향이 거의 없는 것으로 나타났다. 이에 따라, 경력 이외의 학습자 특성에 집중함으로써, 학습자 맞춤형 교육 콘텐츠를 제공할 필요가 있다.

상기와 같은 분석 결과를 통해, 개인특성에 따라 학습성도에 미치는 영향수준에 차이가 발생하는 것을 확인할 수 있었다. 이러한 분석결과를 활용하여, 개인특성을 고려한 VR 기반 건설안전교육 콘텐츠를 개발할 수 있으며, 이에 따라 학습자에게 더욱 효과적인 안전교육의 기회를 제공할 수 있을 것으로 기대된다.

한편, 본 연구에서는 학습자(실험참가자)의 4가지 개인특성이 학습성도에 미치는 영향을 분석하였는데, 향후 다양한 개인특성에 대한 분석을 수행할 필요가 있다. 또한, 본 연구에서는 30개의 표본을 활용하여, 데이터 분석과 모델 개발을 수행하였는데, 추가 데이터 수집 및 활용을 통해, 분석결과의 일반화 가능성을 검증할 필요가 있다. 더불어, 본 연구에서는 추락사고에 한정하여 안전교육을 수행하였는데, 건설현장에서 발생할 수 있는 다양한 안전사고 유형에 대한 교육 콘텐츠로 확장할 필요가 있다.

## 감사의 글

본 연구는 과학기술정보통신부의 재원으로 한국연구재단의 지원을 받아 수행한 성과입니다(No. NRF-2020R1C1C1004147).



## References

- Breiman, L. (2001). "Random forests." *Machine learning*, 45, pp. 5-32.
- Bzdok, D., Krzywinski, M., and Altman, N. (2017). "Machine learning: a primer." *Nature methods*, 14(12), pp. 1119-1120.
- Chen, T., and Guestrin, C. (2016). "Xgboost: A scalable tree boosting system." *In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785-794.
- Cortes, C., and Vapnik, V. (1995). "Support-vector networks." *Machine learning*, 20, pp. 273-297.
- Dobrowolski, P., Skorko, M., Pochwatko, G., Myśliwiec, M., and Grabowski, A. (2021). "Immersive virtual reality and complex skill learning: transfer effects after training in younger and older adults." *Frontiers in Virtual Reality*, 1, 604008.
- Feng, Y., and Wu, P. (2015). "Risk compensation behaviours in construction workers' activities." *International journal of injury control and safety promotion*, 22(1), pp. 40-47.
- Haslam, R.A., Hide, S.A., Gibb, A.G., Gyi, D.E., Pavitt, T., Atkinson, S., and Duff, A.R. (2005). "Contributing factors in construction accidents." *Applied ergonomics*, 36(4), pp. 401-415.
- Heinrich, H.W. (1941). "Industrial Accident Prevention. A Scientific Approach." *Industrial Accident Prevention. A Scientific Approach.*, (2nd Edition).
- Hoerl, A.E., and Kennard, R.W. (1970). "Ridge regression: applications to nonorthogonal problems." *Technometrics*, 12(1), pp. 69-82.
- Korea Occupational Safety and Health Agency. (2022). "Occurrence of Industrial Accidents in 2022." Accessed: Jun. 10, 2023. [Online]. Available: <https://www.kosha.or.kr/kosha/data/industrialAccidentStatus.do?mode=view&articleNo=438399&article.offset=0&articleLimit=10>
- Lee, K.Y. (2020). "Enhancement of Safety and Health Education towards Improved Awareness of Construction workers." M.E. Dissertation, Hanyang University.
- Liu, H., Li, J., Li, H., Li, H., Mao, P., and Yuan, J. (2021). "Risk Perception and Coping Behavior of Construction Workers on Occupational Health Risks—A Case Study of Nanjing, China." *International journal of environmental research and public health*, 18(13), 7040.
- Loosemore, M., and Malouf, N. (2019). "Safety training and positive safety attitude formation in the Australian construction industry." *Safety science*, 113, pp. 233-243.
- Lundberg, S.M., and Lee, S.I. (2017). "A unified approach to interpreting model predictions." *Advances in neural information processing systems*, 30.
- McCabe, B., Loughlin, C., Munteanu, R., Tucker, S., and Lam, A. (2008). "Individual safety and health outcomes in the construction industry." *Canadian Journal of Civil Engineering*, 35(12), pp. 1455-1467.
- Meng, X., and Chan, A. H. (2020). "Demographic influences on safety consciousness and safety citizenship behavior of construction workers." *Safety science*, 129, 104835.
- Ministry of Employment and Labor. (2021). "Occupational Safety Accident Status." Accessed: Jun. 11, 2023. [Online]. Available: [https://kosis.kr/statHtml/statHtml.do?orgId=118&tblId=DT\\_11806\\_N000&conn\\_path=I2](https://kosis.kr/statHtml/statHtml.do?orgId=118&tblId=DT_11806_N000&conn_path=I2)
- Murtagh, F. (1991). "Multilayer perceptrons for classification and regression." *Neurocomputing*, 2(5-6), pp. 183-197.
- Park, H., and Koo, C. (2022). "Effect of virtual reality-based construction safety education on the learning performance of construction workers - Using CAMIL theory -" *Korean Journal of Construction Engineering and Management*, KICEM, 23(3), pp. 104-115.
- Park, S.W. (2017). "Suggestions on Remedies for Basic Safety and Health Education and New Hire Education in the Construction Industry." M.E. Dissertation, Kyung Hee University.
- Segal, M.R. (2004). "Machine learning benchmarks and random forest regression." UCSF: Center for Bioinformatics and Molecular Biostatistics, pp. 1-14.
- Shapley, Lloyd S. (1953). A value for n-person games, pp. 307-317.
- Shin, K.N., Joo, S.U., and Yang, S.H. (2015). "A Study on the Status and Improvement of the Basic Occupational Safety and Health Training for the Construction Industry : focused on the Educational Methods and Contents." *Journal of the Korea Academia-Industrial Cooperation Society*, 16(5), pp. 3484-3490.
- Smola, A.J., and Schölkopf, B. (2004). "A tutorial on support vector regression." *Statistics and computing*, 14, pp. 199-222.
- Thevaraja, M., Rahman, A., and Gabirial M. (2019). "Recent developments in data science: Comparing linear, ridge and lasso regressions techniques using wine data." *Proceedings of the International Conference on Digital Image & Signal Processing, Oxford United Kingdom*, 1, pp. 1-6.
- Yu, W.D., Wang, K.C., and Wu, H.T. (2022). "Empirical Comparison of Learning Effectiveness of Immersive Virtual Reality - Based Safety Training for Novice and Experienced Construction Workers." *Journal of Construction Engineering and Management*, 148(9), 04022078.



## Appendix




Fig. A1. Local importance of Ridge model




Fig. A2. Local importance of RF model




Fig. A3. Local importance of XGBoost model




Fig. A4. Local importance of MLP model

**요약 :** 건설산업의 높은 재해율을 줄이고자, VR 기반 건설안전교육의 도입이 장려되고 있다. 그러나 학습자의 특성을 고려하지 않은 교육방식으로 인해, 학습자의 개인특성에 맞는 효과적인 교육을 수행하지 못하는 한계가 있다. 본 연구에서는, VR 기반 건설안전교육에서 학습성과에 영향을 미치는 개인특성을 분석하는 것으로 목표로 하였고, 이를 위해 머신러닝과 SHAP 기법을 활용하였다. SHAP 분석 결과, 연령이 학습성과에 가장 많은 영향을 미치는 것으로 나타났고, 경력이 가장 작은 영향을 미치는 것으로 나타났다. 또한, 연령은 학습성과와 음(-)의 상관관계를 보이고 있어, VR 기반 건설안전교육의 도입은 낮은 연령에게 더 효과적일 수 있는 것으로 나타났다. 반면, 학력, 자격, 경력은 양(+)의 상관관계를 보였다. 학력이 낮은 학습자에게 더욱 이해하기 쉬운 콘텐츠를 제공함으로써, 학습성과를 향상시킬 필요가 있다. 또한, 자격과 경력이 낮은 학습자의 특성은 학습성과에 영향을 거의 미치지 않으므로, 그 이외의 학습자 특성에 집중함으로써, 학습자 맞춤형 교육 콘텐츠를 제공할 수 있을 것으로 기대된다. 본 연구를 통해, 여러 개인특성이 학습성과에 서로 다른 영향을 미칠 수 있음을 확인했고, 이러한 결과를 활용함으로써, 건설근로자의 개인특성을 고려한 효과적인 안전교육의 기회를 제공할 수 있을 것으로 기대된다.

**키워드 :** 건설안전교육, 가상현실, 학습성과, 개인특성, 머신러닝과 SHAP