

컴퓨터교육학회 논문지 2025년 제28권 제12호  
https://doi.org/10.32431/kace.2025.28.12.008



# 교사의 AI융합교육 역량에 대한 결정요인 및 잠재 프로파일 분석: TAM, TPACK, 배경 변인을 중심으로\*

## An Analysis of Determinants and Latent Profiles of Teachers' AI Convergence Education Competency: Focusing on TAM, TPACK and Background Variables

이소율<sup>†</sup> · 김귀훈<sup>††</sup>  
Soyul Yi<sup>†</sup> · Kwihoon Kim<sup>††</sup>

### 요약

본 연구는 교사의 AI융합교육 역량 결정 요인을 알아보기 위해 TPACK과 TAM 및 배경 변인을 중심으로 분석하고, 잠재 프로파일 분석(LPA)을 통해 교사 유형을 도출하였다. 이를 위해 68명의 현직 교사를 대상으로 조사를 실시하였으며, 수집된 데이터를 바탕으로 정규성 및 신뢰도 검증, 기술통계, 상관분석을 실시한 후 구조방정식모형(SEM) 분석과 LPA를 수행하였다. 분석 결과, TPACK과 행동의도, 수업 실행, 멘토링, 자기주도학습 여부 등이 주요 영향 요인으로 나타났으며, 교사는 고역량 실천형, 성장잠재형, 소극형 기술중심 집단으로 분류되었다. 본 연구는 교사 맞춤형 연수 및 정책 수립에 기초자료를 제공할 것으로 기대된다.

**주제어** AI융합교육 역량, 교사 배경 변인, TPACK, TAM, 결정요인 분석, 잠재 프로파일 분석

### ABSTRACT

This study aimed to analyze the determinants of teachers' competencies in AI-convergence education based on the TPACK and TAM frameworks, along with key background variables, and to identify latent teacher profiles through Latent Profile Analysis (LPA). Survey data from 68 in-service teachers were analyzed using descriptive statistics, reliability testing, correlation analysis, structural equation modeling (SEM), and latent profile analysis (LPA). Results showed that TPACK, behavioral intention, lesson implementation, mentoring experience, and self-directed learning significantly affected teachers' AI-convergence education competency. LPA identified three teacher profiles: high-capacity practice-oriented, growth-potential, and low-engagement technology-centered groups. The findings suggest the need for tailored professional development and policy efforts to support differentiated teacher competencies in AI-integrated education.

**Keywords** AI-Convergence Education Competency, Teacher Background Variables, TPACK (Technological Pedagogical Content Knowledge), TAM (Technology Acceptance Model), Determinant Analysis, LPA (Latent Profiles Analysis)

†중신회원 강원대학교 교육대학원 조교수  
††중신회원 한국교원대학교 인공지능융합교육전공 부교수(교신저자)  
논문투고 2025년 07월 10일  
심사완료 2025년 09월 05일  
게재확정 2025년 09월 17일  
발행일자 2025년 12월 31일

## 1. 서론

4차 산업혁명 시대를 이끄는 핵심 기술 중 하나인 인공지능(artificial intelligence, AI)은 경제, 산업, 일상생활, 연구 등 사회 전반에 걸쳐 중대한 영향을 미치고 있다[1]. 특히 교육 분야에서는 AI 기술이 단순한 교육 환경의 변화를 넘어 교수 방법(teaching method), 교육 내용, 평가 패러다임, 학습 경험 전반을 근본적으로 변화시키고 있으며, 이러한 흐름은 점차 가속화되고 있다[2]. 이에 따라 교육부는 2020년 9월, 2015 개정 교육과정의 진로 선택 과목으로 고등학교 실과(기술·가정)/정보 교과에 '인공지능 기초'를, 수학 교과에 '인공지능 수학'을 신설하였다[3]. 이어서 2022 개정 교육과정에서는 정보 교과 역량에 '인공지능 소양'을 추가하고, '디지털 소양'을 기초 소양의 한 축으로 제시하여 AI 및 디지털 역량 함양의 중요성을 한층 더 강조하였다[4]. 특히, 기초 소양은 특정 교과에 국한되지 않고 모든 교과를 통해 통합적으로 강화되어야 한다고 제시되어 있어, AI를 포함한 디지털 융합 교육이 전 교과에 걸쳐 이루어져야 한다고 해석할 수 있다. 이는 교육부의 정책 방향에 국한된 것이 아니라, AI를 다양한 학문 및 교과와 융합하는 교육적 접근이 학습자의 생활 문제 해결력과 창의적 사고력 함양에 기여함으로써, 미래 사회가 요구하는 융합형 인재를 양성하는데 핵심적인 역할을 할 수 있다는 점에서 더욱 중요한 의미를 지닌다[5].

이러한 배경에서 AI융합교육은 미래 교육의 핵심 방향으로 부상하고 있으며, 이는 단지 AI 기술에 대한 단편적인 이해를 넘어, 이를 다양한 교육적 맥락 속에 통합할 수 있는 융합적 사고와 실천적 역량이 요구한다[6]. 따라서 AI융합교육의 실질적인 구현을 위해서는 교사가 중심적인 역할을 수행할 수 있어야 하며, 이를 가능하게 하기 위해서는 교사가 AI융합교육 역량을 체계적으로 함양할 필요가 있다[7]. 이러한 역량은 기술적 이해 뿐 아니라 교육 과정 재구성, 수업 설계 및 실행, 교육적 윤리와 가치 판단에 이르기까지 다면적인 요소를 포함한다. 따라서 교육부는 '디지털 기반 교육 혁신 방안', AIEDAP 사업 등을 통해 사업 등을 통해 예비 및 현직 교원의 AI·디지털 역량 강화를 적극적으로 추진하고 있으며, AI융합교육을 위한 교원 연수 프로그램 및 교육과정 개편을 병행하고 있다[8, 9].

이러한 배경에서 교사에게 요구되는 전문성과 그 구성 요소에 대한 관심 또한 높아지고 있다. 이에 따라 실제 교육현장에서 이러한 역량을 실천할 수 있는 교사의 능력을 체계적으로 측정하고 분석할 필요성이 한층 더 강조되고 있다. 나아가, 효과적인 교사 연수 설계를 위해서도 교사의 역량 형성에 영향을 미치는 요인을 다각적으로 분석한 자료가 필요로 될 수 있다.

한편, 교사의 AI융합교육 역량을 설명하고 예측하기 위한 이론적 프레임워크로는 TPACK(technological pedagogical content knowledge)과 TAM(technology acceptance model)이 있다. TPACK은 교사가 효과적인

AI융합수업을 설계·실행하기 위해 요구되는 기술, 교수, 내용 지식의 통합적 이해를 강조하며, 교사의 실천적 수업 설계 역량을 설명하는 데 강점을 가진다[10, 11]. TAM은 기술에 대한 사용자의 인식이 실제 사용 행동으로 이어지는 과정을 설명하며, 교사의 AI 수업 도구 및 시스템 활용 의도, 수용 정도를 예측하는 데 유용하게 활용된다[12, 13]. 최근에는 이 두 모델을 통합하여 AI 기반 수업에서 교사의 태도, 지식, 신념 등이 어떻게 상호작용하며 사용 의도로 이어지는지를 분석하려는 시도가 활발히 이루어지고 있다[14, 15].

그러나 지금까지의 연구들은 AI융합교육 역량의 구성 요소나 정의를 도출하거나[16-18], 연수 프로그램의 효과성을 분석하는 데 초점을 맞춘 경우가 많으며[7, 19, 20], 교사의 배경 변인과 TPACK 및 TAM 요인이 실제 AI융합교육 역량에 어떠한 영향을 미치는지에 대한 실증적 분석은 부족한 실정이다. 또한, 단순히 AI활용 태도나 기술 수용에만 초점을 둔 기존 연구들은 교사의 인식 수준을 파악하는 데에는 일정 부분 기여할 수 있으나, AI융합교육 역량의 실제적인 발현과 수업 실행력까지를 포괄적으로 설명하는 데에는 한계가 있다[21, 22]. 이러한 연구들은 교사 역량의 구성 요소 간 상호작용, 실제 수업 맥락에서의 적용 가능성, 교육적 실천으로의 전이를 충분히 설명하지 못한다는 점에서 AI융합교육의 복합적 성격을 반영한 다차원적 접근이 요구된다. 이에 따라 교사의 AI융합교육 역량을 보다 구조적이고 다층적으로 이해하기 위해서는 TAM과 TPACK 이론을 통합적으로 고려하는 분석이 요구된다.

이러한 문제의식을 바탕으로, 본 연구는 교사의 AI융합교육 역량에 영향을 미치는 주요 결정요인을 TPACK과 TPACK 이론 그리고 교사의 다양한 배경 변인에 근거하여 분석하고자 한다. 이를 통해 교사의 AI융합교육 역량에 영향을 미치는 요인을 실증적으로 규명함은 물론, 교사 집단의 특성을 반영한 잠재적 프로파일을 탐색함으로써 AI융합교육 역량의 유형화를 시도한다. 이러한 분석은 교사 맞춤형 역량 강화 방안과 연수 설계의 기초자료를 제공할 수 있으며, AI융합교육의 실질적 확산을 위한 전략 수립에 이론적, 실천적 시사점을 제시할 수 있을 것이다.

## 2. 이론적 배경

### 2.1 AI융합교육과 교사 역량

AI융합교육은 인공지능(AI)을 다양한 교과와 학습 활동에 통합하여 가르치는 교육 접근을 의미하며, 4차 산업혁명 시대에 핵심 교육 방향으로 부상하고 있다. 이러한 AI융합교육의 성공적 정착을 위해서는 교사가 AI 기술과 교과 내용, 교수법을 아우르는 역량을 갖추는 것이 필수적이다. 교사의 AI융합교육 역량은 AI에 대한 내용 지식과 활용 기술, 그리고 이를 효과적으로 가르치기 위한 교수 전략을 포함하는데, 최근 연구에서는 이를 내용(content), 교수(pedagogy), 기술(technology) 세 영역으로 구분하여 살

펴보고 있다[23]. 그러나 현실적으로 많은 교사들이 AI융합 교육에 대한 준비도에서 어려움을 느끼고 있다. 임은선 등(2025)의 조사에 따르면 상당수 초등 교사들이 AI융합교육의 중요성에는 공감하면서도 자신의 역량 부족과 자료·시설의 미비를 어려움으로 지적하였다[24]. 이는 우리나라 교사들이 AI융합교육을 위한 지식과 기술적 준비가 충분하지 않음을 보여주며, 교원 연수 강화와 자료 지원 등 정책적 보완의 필요성을 시사한다. 요컨대 AI융합교육 환경에서 교사의 역할은 더욱 복잡해지고 전문성이 요구되며, 이를 뒷받침하기 위해 교사의 융합교육 역량 함양을 체계적으로 지원할 필요가 있다. 이러한 맥락에서 본 연구는 교사의 AI융합교육 역량을 심층적으로 이해하기 위해 이론적 틀로 TPACK과 TAM을 적용하고, 교사 배경 변인을 함께 고려하여 살펴보고자 한다.

## 2.2 TPACK 이론과 교사의 융합교육 실천

교사의 융합교육 역량을 논의할 때 가장 널리 활용되는 이론적 프레임워크 중 하나는 TPACK(technological pedagogical and content knowledge)이다. TPACK은 Mishra와 Koehler(2006)가 제안한 개념으로, 교사가 기술을 교육에 통합하는 데 필요한 세 가지 지식 영역(테크놀로지에 대한 지식, 교수법적 지식, 내용학적 지식)과 그 교차점을 설명한다[10]. 구체적으로 내용 지식(content knowledge, CK), 교수법 지식(pedagogical knowledge, PK), 테크놀로지 지식(technology knowledge, TK)의 세 영역과 이들의 상호 결합인 교수내용 지식(pedagogical content knowledge, PCK), 테크놀로지 교수법적 지식(technological pedagogical knowledge, TPK), 테크놀로지 내용학적 지식(technological content knowledge, TCK), 그리고 세 영역이 통합된 테크놀로지 교수내용 지식인 TPACK으로 구성된다. 이는 교사가 무엇을 가르칠지(교육 내용), 어떻게 가르칠지(교수법), 어떤 기술을 활용할지(테크놀로지)에 대한 통합적인 교육학적 전문 지식을 의미한다[10].

TPACK 프레임워크는 디지털 또는 AI 기술과 같은 테크놀로지를 교육적으로 활용하는 교사의 능력을 평가하거나 연수 프로그램을 설계하는 데 폭넓게 활용되어 왔다. 선행 연구에 따르면 교사의 TPACK 수준이 높을수록 새로운 기술을 수업에 성공적으로 통합할 가능성이 높고, 더 나아가 학생의 학업 성취에도 긍정적 영향을 미칠 수 있다는 보고가 있다[25]. 또한, 최근에는 TPACK 이론이 AI 시대의 융합교육 맥락으로 확장되고 있다. Celik(2023)은 K-12에서의 AI 교육을 위해 TPACK 모형을 수정하여 AI 기술이 교수·학습에 미치는 영향을 반영한 교사 역량 프레임워크를 제안하였고[26], Kim et al.(2021)은 TPACK 관점에서 국내 AI 교육 과정을 분석하여 효과적으로 AI를 가르치기에 필요한 10가지 교사 핵심 역량을 도출하였다[27]. 이와 같이 TPACK은 여러 연구들에서 AI융합교육에 대한 교사의 지식 기반 역량을 이해하고 강화하는 데 핵심 틀로 활용될 수 있다.

## 2.3 TAM 이론과 교사의 기술 수용 태도

교사의 기술 수용 태도를 설명하기 위해 교육공학 분야에서 널리 활용되는 이론으로 TAM(technology acceptance model)이 있다. TAM은 Davis(1989)가 제안한 이론으로, 사용자가 새로운 기술을 받아들이는 과정을 설명하는 대표적 모형이다[12]. TAM의 핵심 가설은 기술에 대한 인지된 유용성(perceived usefulness, PU)과 인지된 사용용이성(perceived ease of use, PEOU)이라는 두 신념이 사용자의 태도(attitude)를 형성하고, 그 태도가 궁극적으로 기술 사용 의도(behavioral intention, BI)에 영향을 준다는 것이다[12]. 즉, 어떤 기술이 유용하고 쉽게 느껴질수록 그 기술에 대한 긍정적 태도가 형성되어 활용 의도가 높아진다는 인과관계를 가정한다. 이후 많은 연구를 통해 실제 교실 현장에서 교사의 새로운 디지털 기술과 같은 테크놀로지 도구 수용 행동을 예측하는 데 TAM의 유용성이 입증되었다[13]. TAM은 교사의 주관적 신념만으로도 기술 수용 행위를 상당 부분 설명해주는 실용적 도구로 평가받고 있고 있으며[13], AI와 같은 새로운 테크놀로지 기술의 학교 현장 도입을 예측하는 모델로도 활용되고 있다.

## 2.4 교사 배경 변인과 교육 역량

개별 교사가 처한 배경 특성은 그들의 교수 역량과 기술 수용 행동에 영향을 줄 수 있는 중요한 요인이다. 여기서 교사 배경 변인이라 함은 성별, 연령, 학력, 교직 경력, 전공 분야(담당 교과), 맡은 교과 및 학년, 연수 경험 등 개인의 인적 속성과 경력을 가리킨다[28]. 선행 연구들은 이러한 배경 요인에 따라 교사의 교육에서의 테크놀로지 활용도와 AI융합교육 또는 STEAM(science, technology, engineering, art and mathematics)와 같은 융합교육 실천에 차이가 나타날 수 있음을 보고해왔다. 예를 들어 일부 연구는 남교사가 여교사보다 자신의 AI와 같은 테크놀로지 활용 능력을 높게 평가하고 자신감도 높게 보이는 경향이 있다고 하였다[28]. 한편 다른 연구들에서는 성별에 따른 유의미한 차이가 발견되지 않기도 하는 등[29] 결과가 일관적이지 않다. 이는 기술 활용에 대한 성별 격차가 맥락과 평가 방식에 따라 다르게 나타날 수 있음을 시사한다. 이 밖에도 연령 및 경력, 전공(담당 교과) 등 교사의 배경 변인에 따라 차이가 있음을 밝힌 여러 연구가 존재한다[30-32]. 따라서 본 연구에서는 교사의 배경 변인을 고려한 분석을 실시하고자 한다.

## 2.5 연구의 차별성

앞서 살펴본 이론들을 종합하면, 교사의 AI융합교육 역량을 이해하기 위해서는 교사의 지식적 요소(예: TPACK 기반 전문성)와 정의적 요소(예: 기술 수용에 대한 태도와 신념), 그리고 개인 배경을 모두 고려하는 통합적 관점이 필요함을 알 수 있다. 선행연구에서는 TPACK과 TAM을 개별적으로 혹은 부분적으로 결합하여 교사의 기술 활용 의도를 설

명하려는 시도가 있었다[13, 14, 15]. 그러나 이러한 연구들은 주로 변인 간 인과 관계를 밝히는 데 초점을 맞추었으며, 교사 집단 내의 잠재적 유형 차이를 드러내는 데에는 한계가 있었다.

본 연구의 차별성은 잠재 프로파일 분석(LPA) 기법을 도입함으로써 교사 집단 내 숨겨진 이질적 특성을 규명하고자 한다는 점에 있다. 잠재 프로파일 분석은 응답 패턴에 따라 유사한 특성을 지닌 교사들을 몇 가지 프로파일로 분류함으로써, 기존 변수 중심 접근으로는 드러나지 않는 교사 유형을 식별할 수 있게 한다[33]. 따라서 본 연구는 TPACK과 TAM 요인을 모두 고려한 문항으로 교사들을 측정된 뒤 LPA를 통해 프로파일을 도출함으로써, 교사의 지식 수준과 기술 수용 태도의 복합적 조합에 따른 유형화를 시도하여 시사점을 도출하고자 한다.

### 3. 연구 방법

#### 3.1 연구 대상 및 수집

연구 대상은 교육대학원 AI융합교육학과에 재학중인 현직 교사로 하였다. 이들은 AI융합교육에 대한 이론적 이해와 실천적 관심을 모두 갖춘 집단으로, 기술수용모델(TAM) 및 TPACK 기반 요인의 분석에 적합하다. 해당 집단은 교육대학원이라는 제도적 동일성과 AI융합교육이라는 전공 일치성을 기반으로 하여, 교사 개인의 배경 변인을 일정 부분 통제할 수 있으며, 이는 변수 간 관계 분석의 타당성을 높이는 데 기여한다. 또한, AI융합교육의 수업 실천 경험, 연수 이수, 자기주도적 학습 등의 다양한 실천적 배경을 갖춘 집단이므로, 단순한 인식 조사가 아닌 역량과 행동 기반 요인 분석에 적합한 표본이라 할 수 있기 때문에 연구 대상으로 선정하였다. 그러나 AI교육에 대한 관심과 동기가 높은 특수 집단일 수 있어 일반 교사 집단에게 확대 해석하기에는 한계가 존재할 수 있음을 명시한다.

자료 조사는 온라인 설문 도구인 Google Form을 활용하였으며, 충청도의 K대학교와 강원도의 K대학교에서 2025년 1월 연구 대상자의 자발적 참여를 통해 수집되었다. 개인 정보를 포함하여 민감정보는 수집하지 않았으며, 모든 내용은 익명으로 조사되었다. 최종 수집된 자료는 68건이며, 불성실 응답은 0건으로 모든 응답을 대상으로 분석을 실시하였다.

#### 3.2 측정 도구

본 연구에서는 교사의 배경 변인, TPACK, TAM, AI융합교육 역량에 대해 측정하였다.

먼저 교사의 배경 변인으로는 선행연구를 기반으로 성별, 지역, 교사 경력, 연령대, 재직 학교급, 담당 교과목 등을 조사 내용으로 선정하였고, 추가로 최대한 많은 배경 변인을 알아 보기 위해 AI융합수업 적용 여부 및 차시 수, 대학원 재학 기간, 자기 주도 학습 여부, AI융합교육과 관련

한 멘토링 및 컨설팅에 참여한 정도 등에 대해 조사하였다. TPACK 문항은 28문항으로 이루어진 TPACK.xs를 한국어로 번안하여 사용했고[35], TAM 문항은 수학 교과를 고려하여 개발된 문항[14]을 일반 수업의 내용으로 수정하여 사용했다. AI융합교육역량 측정 도구[18]는 선행연구에서 개발된 문항 그대로 활용하였다. 각 측정도구의 Cronbach's  $\alpha$ 는 TPACK.xs의 경우 .75에서 .90, TAM의 경우 .85에서 .92, AI융합교육 역량의 경우 전체 .90 이상으로 모든 측정도구의 신뢰도가 확보되었음을 확인할 수 있었다.

#### 3.3 분석 방법

먼저 기초 통계 분석 및 신뢰도 검증을 실시하였고, 집단 간 차이 분석을 위해 t-검정, 일원분산분석, Welch ANOVA 및 사후검정(Tukey HSD)를 실시하였다. 또한, 각 요인 간의 관계를 분석하기 위해 상관 분석을 실시하였으며, 회귀 분석 및 구조방정식 모형 분석을 수행하였다. 마지막으로 교사 특성을 파악하고 유형화 하기 위해 잠재적 프로파일 분석을 수행했다. 분석에 활용한 통계 도구는 Jamovi와 R을 주로 사용하였다.

### 4. 연구 결과

#### 4.1 배경 변인의 기초 통계 및 문항의 신뢰도 분석

##### 4.1.1 배경 변인 분석 결과

Table 1. Descriptive Statistics of Background Variables

Classify		Num(%)
Gender	Male	36(52.9)
	Female	32(47.1)
Region	Metropolitan	20(29.4)
	Rural	48(70.6)
Teaching Career	0-5 years	8(11.8)
	6-10 years	29(42.6)
	11-15 years	20(29.4)
	16-20 years	9(13.2)
	20 years +	2(2.9)
Age Group	20s	5(7.4)
	30s	44(64.7)
	40s	17(25.0)
	50s +	2(2.9)
School Level	Elementary school	23(33.8)
	Middle school	16(23.6)
	High school	29(42.6)
Subject Category	Elementary Education	18(26.5)
	STEM Subject	35(51.5)
	Humanities and Social Sciences	15(22.1)
AI Convergence Class Implementation	Yes	52(76.5)
	No	16(23.5)

Classify		Num(%)
Duration of Study by Semester	1	18(26.5)
	3	12(17.6)
	4	3(4.4)
	5	35(51.5)
	0	18(26.5)
Mentoring or Consulting Involvement Level	1	26(38.2)
	2	15(22.1)
	3	9(13.2)
Self-Directed Learning Experience	Yes	52(76.5)
	No	16(23.5)

본 연구에 참여한 교사의 배경 변인에 대한 기초 통계는 Table 1과 같다. 성별은 남교사 36명(52.9%), 여교사 32명(47.1%)으로 비교적 고르게 분포되어 있다. 근무 지역은 도시권(Metropolitan; 서울, 경기, 세종, 대구, 울산 등) 20명(29.4%), 비도시권(Rural; 그 외 지역) 48명(70.6%)으로, 비도시권 응답자가 더 많았다. 교직 경력에서는 '6-10년'이 29명(42.6%)으로 가장 많았고, 다음으로 '11-15년' 20명(29.4%), '16-20년' 9명(13.2%), '0-5년' 8명(11.8%), '20년 이상' 2명(2.9%) 순이었다. 연령대는 30대가 44명(64.7%)으로 가장 많았으며, 40대 17명(25.0%), 20대 5명(7.4%), 50대 이상은 2명(2.9%)으로 나타났다. 소속 학교급은 고등학교 29명(42.6%), 초등학교 23명(33.8%), 중학교 16명(23.6%) 순으로 분포되었다. 담당 교과 계열은 이공계열(Science, Technology, Engineering, Mathematics; 수학, 과학, 정보 등; STEM Subject)이 35명(51.5%)으로 가장 많았고, 초등교육 전공이 18명(26.5%), 인문사회 계열이 15명(22.1%)이었다. 또한, AI융합수업 실행 여부에서는 '실행 경험 있음'이 52명(76.5%)으로 다수를 차지하였으며, '없음'은 16명(23.5%)이었다. 대학원 재학 학기 수는 5학기 이상이 35명(51.5%)으로 가장 많았고, 1학기 18명(26.5%), 3학기 12명(17.6%), 4학기 3명(4.4%)이었다. 멘토링 또는 컨설팅 참여 수준은 0부터 3수준으로 나누었는데, 0인'참여한 적 없음'이 18명(26.5%), 2인'받은 적 있음'은 15명(22.1%), 3인'제공한 적 있음'이 9명(13.2%)으로 나타났다. 1의 경우 기회가 된다면 받아보고 싶다는 의미인'참여 희망'은 26명(38.2%)이었다. 마지막으로 자기주도 학습 경험은 '있음'이 52명(76.5%)으로 많았고, '없음'은 16명(23.5%)이었다.

이러한 배경 변인은 이후 AI융합교육 역량과의 관련성 분석 및 잠재 프로파일 도출 시 주요한 기준 변수로 활용되었다.

#### 4.1.2 TPACK, TAM 및 AI 융합교육역량의 기초 통계 및 신뢰도 분석 결과

**Table 2.** Descriptive and Reliability Analysis of TPACK, TAM, and AICEC(AI Convergence Education Competency)

Classify		M	SD	Skew.	Kurt.	Cronbach's $\alpha$
TPACK <sub>xs</sub>	CK	4.33	0.627	-0.508	-0.863	0.863
	TK	4.29	0.690	-0.945	0.259	0.861
	PCK	4.26	0.727	-0.889	0.190	0.854
	TPK	4.28	0.671	-0.505	-0.722	0.896
	TCK	4.21	0.717	-0.400	-0.902	0.921
	TPCK	4.31	0.710	-0.671	-0.536	0.961
	Total	4.28	0.590	-0.375	-0.969	0.965
TAM	PEOU	3.89	0.859	-0.422	-0.497	0.858
	PU	4.31	0.727	-0.837	-0.117	0.922
	Attitude	4.25	0.707	-0.619	-0.289	0.849
	BI	4.23	0.733	-0.812	0.118	0.901
	Total	4.17	0.696	-0.577	-0.511	0.958
AICEC	AIL	4.07	0.802	-0.682	-0.007	0.953
	AIED	4.16	0.807	-0.595	-0.758	0.961
	AICEL	4.28	0.749	-1.000	0.700	0.963
	AICEI	4.28	0.749	-0.894	0.263	0.979
	Total	4.18	0.757	-0.747	-0.011	0.988

Table 2는 교사의 AI융합교육 역량(AI Convergence Education Competency, AICEC)과 그 관련 요인인 TPACK 및 TAM 변인의 기술 통계량과 내적 신뢰도를 분석한 결과이다. 먼저, TPACK 구성요소의 평균은 전반적으로 높은 수준을 보였다. 내용지식(CK)은  $M = 4.33(SD = 0.627)$ 으로 가장 높았으며, 기술지식(TK)은  $M = 4.29(SD = 0.690)$ , 교수내용지식(PCK)은  $M = 4.26(SD = 0.727)$ , 기술-교수지식(TPK)은  $M = 4.28(SD = 0.671)$ , 기술-내용지식(TCK)은  $M = 4.21(SD = 0.717)$ , 통합지식(TPCK)은  $M = 4.31(SD = 0.710)$ 로 나타났다. 전체 TPACK 평균은 4.28( $SD = 0.590$ )로 비교적 고르게 분포되어 있었으며, 신뢰도 계수(Cronbach's  $\alpha$ )는 .854~.961로 매우 높게 나타나 각 하위요소의 일관성이 충분히 확보되었음을 보여준다.

둘째, TAM 구성요소 또한 긍정적인 수준으로 평가되었다. 인지된 사용용이성(PEOU)은  $M = 3.89(SD = 0.859)$ , 인지된 유용성(PU)은  $M = 4.31(SD = 0.727)$ , 태도(Attitude)는  $M = 4.25(SD = 0.707)$ , 행동의도(BI)는  $M = 4.23(SD = 0.733)$ 로 측정되었다. TAM 전체 평균은 4.17( $SD = 0.696$ )이며, 신뢰도는 .849~.922 범위로 역시 높은 내적 일관성을 보였다.

셋째, AI융합교육역량(AICEC)은 모든 하위요소에서 높은 평균과 우수한 신뢰도를 보였다. AI에 대한 이해를 나타내는 AI 리터러시(AI literacy, AIL)는  $M = 4.07(SD = 0.802)$ , AI의 교육에의 적용 및 실천(AI in Education, AIED)은  $M = 4.16(SD = 0.807)$ , AI융합수업의 이해 수준(AI Convergence Education Literacy, AICEL)은  $M = 4.28(SD = 0.749)$ , AI융합교육의 실행과 평가(AI Convergence Education Implementation and evaluation, AICEI)는  $M = 4.28(SD = 0.749)$ 로 나타났으

며, 전체 평균은  $M = 4.18$ ( $SD = 0.757$ )로 확인되었다. 특히, Cronbach's  $\alpha$ 는 모두 .95 이상으로 매우 높은 신뢰도를 보였고, 전체 총합의 경우  $\alpha = .988$ 로 측정되었다.

전반적으로 모든 변인에서 왜도(Skewness)와 첨도(Kurtosis)는 절대값 2 이하로 나타나 정규분포의 가정을 충족하며, 문항 구성의 타당성과 내적 신뢰도 또한 양호한 수준임을 확인할 수 있다. 아울러, 추후 진행할 구조방정식 모형 검증에 앞서 정규성 충족 여부를 확인한 결과, 왜도의 절대값이 3 미만이고, 첨도의 절대값이 7 미만이면, 정규성에 큰 문제가 없는 것으로 간주할 수 있으며[36], 본 연구에서도 이러한 기준을 만족함으로써 다변량 정규성 가정을 충족하는 것으로 판단된다.

## 4.2 교사 배경 변인이 AI융합교육 역량에 미치는 영향

### 4.2.1 성별, 지역, 교직 경력, 연령대에 따른 차이

Table 3. Differences in AICEC by Gender

Gender	n	M	SD	t(df)	p	Cohen's d
Male	36	3.82	0.45	-0.91(66)	.366	0.13
Female	32	3.91	0.42			

※ Levene's test:  $F(1, 66) = 1.51, p = .224$  (equal variances assumed).

Table 3와 같이 성별에 따른 교사의 AI융합교육 역량 차이를 확인하기 위해 독립표본 t-검정을 실시한 결과, 남교사( $M = 4.15, SD = 0.82$ )와 여교사( $M = 4.23, SD = 0.69$ ) 간의 평균 차이는 통계적으로 유의하지 않았다( $t(66) = -0.45, p = .654$ ). 등분산성 가정은 Levene의 검정에서  $p = .224$ 로 충족되었으며, 효과크기(Cohen's  $d = 0.13$ )는 매우 작은 수준으로 나타났다. 이는 성별에 따른 AI융합교육 역량의 실질적인 차이가 존재하지 않음을 시사한다.

Table 4. Differences in AICEC by Region

Region	n	M	SD	t(df)	p	Cohen's d
Metropolitan	20	4.33	0.74	0.99(66)	.325	0.264
Rural	48	4.13	0.77			

※ Levene's test:  $F(1, 66) = 0.143, p = .706$  (equal variances assumed).

Table 4와 같이 지역에 따른 교사의 AI융합교육 역량 차이를 살펴보기 위해 독립표본 t-검정을 실시한 결과, 도시권(Metropolitan) 교사( $M = 4.33, SD = 0.74$ )와 비도시권(Rural) 교사( $M = 4.13, SD = 0.77$ ) 간의 평균 차이는 통계적으로 유의하지 않았다( $t(66) = 0.99, p = .325$ ). 등분산성 가정을 확인한 Levene 검정 결과  $F = 0.143, p = .706$ 으로 등분산성이 충족되었으며, 효과크기(Cohen's  $d = 0.264$ )는 작은 수준으로 나타났다. 이는 지역에 따라 AI융합교육 역량에 다소 차이는 있으나, 통계적으로 유의미한 수준은 아님을 보여준다.

Table 5. Differences in AICEC by Teaching Career

Career	n	M	SD	F(df)	p
0-5 years	8	4.09	0.97	1.08(4, 63)	.427
6-10 years	29	4.16	0.72		
11-15 years	20	4.20	0.83		
16-20 years	9	4.43	0.62		
20 years +	2	3.70	0.34		

※ Levene's test:  $F(4, 63) = 0.723, p = .580$  (equal variances assumed).

※ Post hoc test(Tukey HSD): No significant differences found between groups.

Table 5와 같이 교사의 교직 경력에 따른 AI융합교육 역량 차이를 살펴보기 위해 일원분산분석(One-way ANOVA)을 실시한 결과, 다섯 집단 간 평균 차이는 통계적으로 유의미하지 않은 것으로 나타났다( $F(4, 63) = 1.08, p = .427$ ). 등분산성 가정을 검토한 Levene 검정 결과  $p = .580$ 으로 등분산성이 충족되었으며, 사후검정(Tukey HSD)에서도 모든 집단 간 비교에서 유의한 차이는 나타나지 않았다( $p > .05$ ). 다만, 평균값 비교에서는 '16~20년' 경력 교사 집단이 가장 높은 AI융합교육 역량 평균( $M = 4.43$ )을 보였으나, '20년 이상' 집단은 오히려 가장 낮은 평균( $M = 3.70$ )을 보여, 경력의 많고 적음보다는 다른 요인이 역량에 더 밀접한 영향을 줄 수 있음을 나타낸다.

Table 6. Differences in AICEC by Age Group

Age Group	n	M	SD	F(df)	p
20s	5	4.01	1.07	1.18(3, 64)	.408
30s	44	4.25	0.70		
40s	17	4.12	0.88		
50s +	2	3.70	0.34		

※ Levene's test:  $F(3, 63) = 1.400, p = .251$  (equal variances assumed).

※ Post hoc test(Tukey HSD): No significant differences found between groups.

Table 6과 같이 연령대에 따른 교사의 AI융합교육 역량 차이를 분석하기 위해 일원분산분석(One-way ANOVA)을 실시한 결과, 네 집단 간 평균 차이는 통계적으로 유의미하지 않았다( $F(3, 64) = 1.18, p = .408$ ). Levene 검정을 통해 등분산성 가정이 충족되었음이 확인되었으며( $p = .251$ ), 사후검정(Tukey HSD) 결과 또한 모든 집단 간 평균 차이가 유의하지 않았다( $p > .05$ ).

평균값 비교 결과, 30대 집단( $M = 4.25$ )이 가장 높은 역량 수준을 보였으며, 50대 이상 집단( $M = 3.70$ )이 가장 낮았지만, 통계적으로 유의미한 차이를 보이지는 않았다. 이는 AI융합교육 역량이 연령보다는 다른 요인과 더 밀접하게 관련될 수 있음을 시사한다.

### 4.2.2 재직 학교급, 담당 과목 계열, AI융합수업 실천 등에 따른 차이

**Table 7.** Differences in AICEC by School Level

School Level	n	M	SD	F(df)	p
Elementary	23	4.44	0.68	2.30(2, 65)	.113
Middle	16	4.14	0.70		
High	29	4.01	0.81		

※Levene’s test:  $F(2, 65) = 0.431, p = .652$  (equal variances assumed).

※Post hoc test(Tukey HSD): No significant differences found between groups.

Table 7과 같이 교사가 소속된 학교급에 따른 AI융합 교육 역량 차이를 확인하기 위해 일원분산분석(One-way ANOVA)을 실시한 결과, 초등학교, 중학교, 고등학교 간 평균 차이는 통계적으로 유의하지 않은 것으로 나타났다( $F(2, 65) = 2.30, p = .113$ ). 등분산성 검정을 위한 Levene 검정 결과  $p = .652$ 로 등분산성이 충족되었으며, 사후검정(Tukey HSD) 결과 역시 모든 집단 간에서 유의한 평균 차이는 관찰되지 않았다( $p > .05$ ).

평균값 비교에서는 초등학교 교사(M = 4.44)가 가장 높은 AI융합교육 역량을 보였고, 고등학교 교사(M = 4.01)가 가장 낮았지만 이 차이는 통계적으로 유의하지 않았다. 이는 초등학교 교사들이 비교적 다양한 교과 융합이나 디지털 기반 프로젝트 수업에 더 자주 노출될 수 있음을 나타낸다고 볼 수 있지만, 통계적 검증을 위해서는 보다 큰 표본이 필요할 수 있다.

**Table 8.** Differences in AICEC by Subject Categories

Subject Categories	n	M	SD	F(df)	p
Elementary Education	18	4.52	0.50	8.76(2, 65)	< .001
Humanities and Social Sciences	15	3.65	0.65		
STEM Subjects	35	4.24	0.80		

※Levene’s test:  $F(2, 65) = 0.431, p = .652$  (equal variances assumed).

Table 8과 같이 교사의 담당 교과 계열에 따른 AI융합교육 역량 차이를 분석하기 위해 일원분산분석(ANOVA)을 실시한 결과, 세 집단 간의 평균 차이는 통계적으로 유의하였다( $F(2, 65) = 8.76, p < .001$ ). Levene의 등분산성 검정 결과  $p = .652$ 로 등분산성이 충족되었으며, 사후검정(Tukey HSD) 결과, 초등교육 교사(M = 4.52)는 인문사회계열 교사(M = 3.65)보다 유의미하게 높은 AI융합교육 역량을 보였다( $p = .002$ ), 이공계열 전공 교사(M = 4.24) 또한 인문사회계열 교사보다 유의미하게 높은 수준을 나타냈다( $p = .022$ ).

이는 초등 및 이공계열 분야 교사들이 인문사회계열 교사보다 AI융합교육 경험, 디지털 기술 활용 빈도, 융합 수업 설계 경험이 더 풍부할 수 있음을 시사한다.

**Table 9.** Tukey HSD Post Hoc Comparison for Subject Area on AICEC

Comparison	MD	t	df	p
Elementary Education vs. Humanities and Social Sci.	0.867	3.53	65.0	.002**
Elementary Education vs. STEM Subjects	0.276	1.36	65.0	.369
STEM Subjects vs. Humanities & Social Sci.	0.590	2.72	65.0	.022*

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

Tukey HSD 사후검정 결과는 Table 9와 같다. 초등교육 계열 교사(M = 4.52, SD = 0.50)는 인문사회계열 교사(M = 3.65, SD = 0.65)보다 유의미하게 높은 AI융합교육 역량을 보였다( $p = .002$ ). 또한 이공계열 교사(M = 4.24, SD = 0.80) 또한 인문사회계열 교사보다 역량 수준이 유의미하게 높게 나타났다( $p = .022$ ).

이러한 결과는 초등교육 및 이공계열 교사들이 인문사회계열 교사들보다 AI융합교육에 대한 경험, 디지털 기술의 활용 빈도, 융합적 수업 설계 경험 등이 더 풍부할 수 있음을 시사하며, 향후 인문사회계열 교사들을 위한 AI융합교육 연수 및 지원이 강화될 필요성에 대한 근거가 될 수 있다고 해석된다.

**Table 10.** Differences in AICEC by AI Convergence Education Class Implementation

AICE Class Implementation	n	M	SD	t(df)	p	Cohen’s d
Yes	52	4.45	0.539	-6.75(66)	< .001	-1.93
No	16	3.32	0.726			

※Levene’s test:  $F(1, 66) = 0.490, p = .486$  (equal variances assumed).

Table 10과 같이 AI융합수업 실행 여부에 따른 교사의 AI융합교육 역량 차이를 분석한 결과, AI융합수업을 실시한 교사(M = 4.45, SD = 0.54)가 그렇지 않은 교사(M = 3.32, SD = 0.73)에 비해 통계적으로 유의미하게 높은 역량을 보였다,  $t(66) = -6.75, p < .001$ . 등분산성 가정은 Levene의 검정에서  $p = .486$ 로 충족되었으며, 효과크기(Cohen’s  $d = -1.93$ )는 매우 큰 수준으로 나타나, AI융합수업 실행 경험이 교사의 AI융합교육 역량에 강력한 영향을 미칠 수 있음을 시사한다.

**Table 11.** Distribution of Implemented AI Convergence Lessons

Hours of Implemented Lessons	Numbers	Percent(%)
0	16	23.53
1~15	29	42.65
16~30	13	19.12
31~45	3	4.41
45 +	7	10.29

Table 11은 교사들이 실행한 AI융합수업 차시 수에 대한 분포를 나타낸 것이다. 앞서 Table 10과 같이 수업을 전혀 실행하지 않은 교사는 16명(23.53%)이었다. 실행 경험이 있는 교사들 중 1-15차시 정도 실행했다고 응답한 교사는 29명(42.65%)으로 가장 많았고, 16-30차시는 13명(19.12%), 31-45차시는 3명(4.41%), 45차시 이상은 7명(10.29%)으로 나타났다.

**Table 12.** Correlation Between Number of Implemented Lessons and AICEC

Variable Pair	Pearson's r	p
0Number of Implemented Lessons ↔ AICEC	.257*	.034

\*  $p < .05$ ,  $N = 68$

Table 12와 같이 AI융합수업의 실행 경험과 AI융합교육 역량 간의 관계를 살펴보기 위해 Pearson 상관분석을 실시한 결과, 두 변수 간에는 통계적으로 유의미한 정적 상관관계가 나타났다( $r = .257$ ,  $p = .034$ ). 이는 AI융합수업을 더 많이 실시한 교사일수록 AI융합교육 역량이 더 높게 나타나는 경향이 있음을 시사하며, 단순한 인식 차원을 넘어 실제 수업 실천 경험이 교사의 역량 형성에 영향을 줄 수 있음을 의미한다.

**4.2.3 대학원 재학 기간, 멘토링 및 컨설팅 참여 수준, 자기 주도 학습 정도 등에 따른 차이**

**Table 13.** Differences in AICEC by Duration of Graduate Study

Semester	n	M	SD	F(df)	p
1 semester	18	3.65	0.739	5.48 (3, 8.76)	.021
3 semester	12	4.04	0.590		
4 semester	3	4.10	0.853		
5 semester	35	4.52	0.656		

※Levene's test:  $F(3, 64) = 0.188$ ,  $p = .904$  (equal variances assumed).

Table 13과 같이 대학원 재학 학기 수에 따른 교사의 AI융합교육 역량 차이를 분석하기 위해 일원분산분석(one-way ANOVA)을 실시한 결과, 네 집단 간의 평균 차이는 통계적으로 유의하였다( $F(3, 64) = 5.48$ ,  $p = .021$ ). Levene의 등분산성 검정 결과  $p = .904$ 로 등분산성이 충족되었으며, 평균 비교 결과 5학기 이상 재학한 교사( $M = 4.52$ )가 1학기 재학 교사( $M = 3.65$ )보다 높은 역량을 보였다. 이는 대학원 교육의 지속적인 참여가 AI융합교육 역량 함양에 긍정적 영향을 미칠 수 있음을 시사한다.

**Table 14.** Tukey HSD Post Hoc Comparison for Graduate Study Duration on AI Convergence Education Competency

Comparison	MD	t	df	p
1 semester vs. 3 semesters	-0.389	1.12	64.0	.417
1 semester vs. 4 semesters	-0.450	0.95	64.0	.710
1 semester vs. 5 semesters	-0.865	3.84	64.0	< .001***
3 semesters vs. 4 semesters	-0.061	0.01	64.0	.999
3 semesters vs. 5 semesters	-0.476	1.40	64.0	.163
4 semesters vs. 5 semesters	-0.415	0.72	64.0	.738

\*\*\*  $p < .001$

Table 14와 같이 Tukey HSD 사후검정 결과, 5학기 이상 재학한 교사는 1학기 재학 교사보다 유의미하게 높은 AI융합교육 역량 평균을 보였다( $MD = -0.865$ ,  $t(64) = 3.84$ ,  $p < .001$ ). 반면, 1학과 3·4학기, 3학과 4·5학기 등의 비교에서는 통계적으로 유의미한 차이가 나타나지 않았다. 이는 대학원 과정의 지속적인 교육 경험이 AI융합교육 실천 역량 향상에 긍정적인 영향을 미칠 수 있음을 시사하며, 특히 일정 수준 이상의 학습 경험 축적이 중요함을 보여준다.

**Table 15.** Differences in AICEC by Mentoring/Consulting Involvement Level

Involvement Level	n	M	SD	F(df)	p
0 = Never participated	18	3.83	0.916	23 (3, 31.6)	< .001
1 = Want to participate in the future	26	4.22	0.647		
2 = Have received mentoring/consulting	15	4.11	0.657		
3 = Have provided mentoring/ consulting to others	9	4.94	0.113		

※Levene's test:  $F(3, 64) = 7.35$ ,  $p = .001$  (Equal variance assumption violated).

Table 15와 같이 멘토링 또는 컨설팅 참여 수준에 따른 교사의 AI융합교육 역량 차이를 분석하였다. AI융합교육과 관련한 멘토링 또는 컨설팅 참여 수준은 다음과 같이 정의되었다. 수준 0은 받아본적 없고 받을 계획 없음, 수준 1은 받아본적 없지만 앞으로 기회가 된다면 받아보고 싶음, 수준 2는 받아본적 있음, 수준 3은 타인에게 제공한 경험 있음이다. Levene의 등분산성 검정 결과  $p = .001$ 로 등분산성이 충족되지 않아 Welch 방법이 적용되었다. Welch 일원분산분석(one-way ANOVA) 결과, 네 집단 간의 평균 차이는 통계적으로 유의하였다( $F(3, 31.6) = 23.0$ ,  $p < .001$ ). 평균값 비교 결과, 멘토링이나 컨설팅을 제공한 경험이 있는 교사( $M = 4.94$ ,  $SD = 0.113$ )가 다른 모든 집단에 비해 가장 높은 역량을 보였고, 이는 통계적으로 유의미하였다. 반면, 참여 경험이 없는 교사 및 수혜 경험만 있는 교사들의 평균은 상대적으로 낮았다. 이는 멘토링이나 컨설팅을 제공하는 사람은 높은 AI융합교육 역량을 지니고 있음을 시사하며, 멘토 또는 컨설턴트로서의 활동 경험이 교사의 AI융합교육 역

량 강화에 도움이 될 수 있다고 해석된다.

**Table 16.** Tukey HSD Post Hoc Comparison for Mentoring/ Consulting Involvement Level on AICEC

Comparison	MD	t	df	p
0 vs 1	-0.389	-1.83	64.0	.271
0 vs 2	-0.278	-1.15	64.0	.663
0 vs 3	-1.114	-3.93	64.0	.001***
1 vs 2	0.111	0.491	64.0	.961
1 vs 3	-0.725	-2.70	64.0	.043**
2 vs 3	-0.836	-2.85	64.0	.029**

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

Table 16과 같이 Tukey HSD 사후검정 결과, 멘토링이나 컨설팅을 제공한 경험이 있는 교사(수준 3)는 멘토링 경험이 없는 교사(수준 0), 참여 희망자(수준 1), 받은 경험이 있는 교사(수준 2)에 비해 통계적으로 유의미하게 높은 AI융합교육 역량을 보였다. 특히, '0 vs 3' 비교에서는 MD = -1.114( $t(64) = -3.93, p = .001$ ), '1 vs 3'에서는 MD = -0.725( $p = .043$ ), '2 vs 3'에서는 MD = -0.836( $p = .029$ )로 모두 통계적으로 유의미하게 나타났다. 반면, 수준 0, 1, 2 간의 비교에서는 통계적으로 유의한 차이가 나타나지 않았다( $p > .05$ ). 이러한 결과는 멘토링 수혜 여부보다 제공자 경험이 AI융합교육 역량 형성에 더욱 결정적인 영향을 줄 수 있음을 시사한다.

**Table 17.** Correlation Between Mentoring/Consulting Involvement Level and AICEC

Variable Pair	Spearman's $\rho$	p
Mentoring/Consulting Involvement Level ↔ AICEC	.348	.004**

\*\*  $p < .01, n = 68$

Table 17과 같이 교사의 멘토링 및 컨설팅 참여 수준과 AI융합교육 역량 간의 관계를 확인하기 위해 상관분석을 실시한 결과, 두 변수 간에는 통계적으로 유의미한 정적 상관관계가 나타났다 ( $\rho = .348, p = .004$ ). 이는 교사의 멘토링·컨설팅 참여 정도가 높을수록 AI융합교육 역량 또한 높은 경향이 있음을 의미하며, 단순한 참여 여부뿐만 아니라 참여 수준의 심화 정도(예: 수혜자 vs. 제공자)가 역량 발달과 유의미하게 관련되어 있음을 뒷받침한다.

**Table 18.** Differences in AICEC by Self-Directed Learning Experience

Involvement Level	n	Mean	SD	F(df)	p	Cohen's d
No self-directed learning	9	3.63	0.784	-2.85(64)	.006**	-1.02
Engaged in self-directed learning	57	4.32	0.659			

\*\*  $p < .01$

※Levene's test:  $F(1, 64) = 0.257, p = .614$  (equal variances assumed).

Table 18과 같이 교사의 자기주도 학습 여부에 따라 AI융합교육 역량에 차이가 있는지를 확인하기 위해 독립표본 t-검정을 실시한 결과, 강의나 연수 외에 자기주도 학습을 실시한 교사(M = 4.32, SD = 0.66)는 그렇지 않은 교사(M = 3.63, SD = 0.78)에 비해 통계적으로 유의미하게 높은 AI융합교육 역량을 보였다( $t(64) = -2.85, p = .006$ ). 등분산성 가정은 Levene's 검정 결과( $p = .614$ )에서 충족되었으며, 효과크기(Cohen's  $d = -1.02$ )는 매우 큰 수준으로 나타났다. 이러한 결과는 AI융합교육 역량 향상에 있어 개인의 자기주도적 탐색과 학습 경험이 중요한 역할을 함을 시사한다. 단순한 수동적 연수 참여보다, 자발적인 학습 참여가 역량 강화에 보다 효과적일 수 있음을 보여준다.

**Table 19.** Differences in AICEC by Grouped Self-Directed Learning Topic

Grouped Topic	n	M	SD	F(df)	p
1. Generative AI and Coding	25	4.38	0.636	1.47 (4, 6.17)	.318
2. Lesson Implementation and Instructional Design	12	4.31	0.553		
3. Data Analysis and Certification-Oriented Learning	4	4.75	0.296		
4. Trend Exploration and Self-Development	14	4.17	0.705		
Other (non-response or irrelevant)	2	3.80	1.294		

$n = 57$

※Levene's test:  $F(3, 64) = 7.35, p = .001$  (Equal variance assumption violated).

※Shapiro-Wilk Normality Test:  $W = 0.936, p = .005$  (Normality assumption violated).

Table 19는 자기주도 학습을 한다는 교사들의 학습 목적 및 주제, 내용에 대해 단답형으로 응답한 결과를 토대로 1. 생성형 AI 및 코딩, 2. AI융합수업 적용 및 수업 설계, 3. 데이터 분석 및 자격증 학습, 4. 트렌드 이해 및 자기 개발로 나누었고 무응답 및 기타의 총 5 범주로 나누었다.

등분산성 가정은 Levene의 검정 결과  $p = .001$ 로 위배되었고, 정규성 검정(Shapiro-Wilk test) 또한  $p = .005$ 로 통계적으로 유의하여 정규분포 가정을 만족하지 않았다. 이로 인해 Welch 방식이 적용되었다.

Welch 일원분산분석(one-way ANOVA)을 실시한 결과, 다섯 개 주제 간의 평균 차이는 통계적으로 유의하지 않았다( $F(4, 6.17) = 1.47, p = .318$ ).

이러한 결과는 자기주도 학습의 내용보다는 학습 실행 자체가 역량 형성에 더 중요한 역할을 할 수 있음을 시사한다.

#### 4.2.4 교사의 배경 변인별 차이 요약

Table 20은 본 연구에서 분석한 교사 배경 변인별 AI융합교육 역량 차이에 대한 통계적 검정 결과를 요약한 것이

다. 총 11개의 배경 변인을 대상으로 독립표본 t-검정, 일원 분산분석(one-way ANOVA), Welch ANOVA 등의 분석이 수행되었으며, 그 결과 다음과 같은 시사점을 도출할 수 있다.

**Table 20.** Summary of Group Differences in AICEC by Teacher Background Variables

Background Variables	Statistical Test	Significant(p)	Result
Gender	Independent t-test	.366	Not significant
Region	Independent t-test	.264	Not significant
Teaching Carrer	One-way ANOVA	.427	Not significant
Age Group	One-way ANOVA	.408	Not significant
School Level	One-way ANOVA	.113	Not significant
Subject Categoires	One-way ANOVA	< .001***	Significant
AI Convergence Class Implementation	Independent t-test	< .001***	Significant
Graduate Study Duration	Welch's ANOVA	.021*	Significant
Mentoring/Consulting Involement Level	Welch's ANOVA	< .001***	Significant
Self-Directed Learning (Y/N)	Independent t-test	.006*	Significant

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

첫째, 성별, 지역, 교직경력, 연령, 학교급에 따른 역량 차이는 통계적으로 유의하지 않았다(Table 3~7). 이는 기존 연구에서 보고된 일부 결과들과 유사하며[37], AI융합교육 역량은 성별이나 연령보다도 실제 실천적 경험과 더 밀접한 관련이 있음을 시사한다.

둘째, 담당 교과 계열에 따른 유의미한 차이가 나타났다 ( $p < .001$ ). 초등교육 전공 및 이공계열 교사가 인문사회계열 교사보다 AI융합교육 역량이 유의하게 높게 나타났으며 (Table 8, 9), 이는 관련 기술 활용 경험 및 교과 특성의 차이에 기인한 것으로 볼 수 있다.

셋째, AI융합수업 실행 여부 및 실행 차시 수는 역량에 큰 영향을 주는 요인으로 확인되었다. 수업을 실시한 교사는 미실시 교사보다 역량이 유의하게 높았고(Table 10), 실행 차시 수 역시 역량과 유의미한 정적 상관관계를 보였다( $r = .257$ ,  $p < .05$ ; Table 11, 12). 이는 교사의 실천 및 경험 기반 학습의 중요성을 뒷받침하며[7], 단순 이수보다 실제 수업 적용이 역량 강화에 효과적임을 나타낸다.

넷째, 대학원 재학 학기 수가 증가할수록 AI융합교육 역량도 유의미하게 증가하는 경향을 보였으며( $p = .021$ ; Table 13, 14), 이는 지속적인 교육 참여가 전문성에 긍정적인 영향을 미칠 수 있음을 시사한다.

다섯째, 멘토링 또는 컨설팅 참여 수준은 매우 유의한 영향을 미치는 요인으로 확인되었다. 특히, 멘토링·컨설팅을

제공한 교사는 모든 다른 집단에 비해 가장 높은 역량을 보였으며( $p < .001$ ; Table 15, 16), 참여 수준과 역량 간에는 유의미한 정적 상관관계도 나타났다( $\rho = .348$ ,  $p = .004$ ; Table 17). 이는 단순 수혜자보다 실천적 리더십 경험이 교사의 역량 강화에 기여함을 보여준다.

여섯째, 자기주도학습 경험 유무에 따른 역량 차이도 통계적으로 유의하였으며( $p = .006$ ; Table 18), 자기주도적 탐색과 학습 실행이 역량 형성에 중요한 영향을 준다는 점을 확인하였다. 반면, 학습 주제별 역량 차이는 유의하지 않았지만, ‘데이터 분석’ 또는 ‘생성형 AI’ 등 실천적 주제를 다룬 교사들의 평균이 높게 나타난 경향은 주목할 만하다 (Table 19). 이는 학습 내용보다 자발적 학습 태도와 실행 여부가 더 중요한 요인일 수 있음을 시사한다.

이상의 결과는 AI융합교육 역량의 형성과정에서 단순한 배경 변인보다는 실천적 경험(수업 실행, 멘토링 제공, 자기주도 학습 등)이 더 큰 영향을 미친다는 기존 연구들의 주장 [38, 7, 14]과 맥을 함께 한다.

### 4.3 TPACK, TAM이 AI융합교육 역량에 미치는 영향

#### 4.3.1 상관 분석 결과

TPACK과 AI융합교육 역량, TAM과 AI융합교육역량, 그리고 TPACK과 TAM 사이의 관계를 알아보기 위해 상관 분석을 시행하였다.

**Table 21.** Correlation Matrix of TPACK, TAM, and AICEC

	TPACK	TAM	AICEC
TPACK	1		
TAM	0.698	1	
AICEC	0.788	0.710	1

\*\*\*  $p < .001$

Table3과 같이 Pearson 상관분석을 실시한 결과, 세 변수 간에는 모두 통계적으로 유의미한 정적 상관관계가 나타났다( $p < .001$ ). 이는 TPACK과 TAM이 AI융합교육 역량과 모두 밀접한 관계를 가지며, 각 이론 모형이 교사의 역량 형성에 중요한 설명력을 가질 수 있음을 시사한다.

#### 4.3.2 중다 회귀 분석 결과

**Table 22.** Multiple Regression of TPACK, TAM Predicting AICEC

Predictor	B	SE	$\beta$	t	p
(Intercept)	4.185	0.0535	—	78.26	< .001***
TPACK	0.733	0.1275	0.571	5.75	< .001***
TAM	0.339	0.1081	0.312	3.14	
F(p)	66.33( $p < .001$ )				
Adj. R2	.661				

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

TPACK과 TAM이 AI융합교육 역량(AICEC)에 미치는 영향을 파악하기 위해 다중회귀분석을 실시한 결과는 Table 22와 같다. 두 변수 모두 유의미한 예측변인으로 나타났다. TPACK은 AICEC에 정(+)적인 영향을 미쳤다( $\beta = .571, p < .001$ ). TAM 또한 유의미한 정적 효과를 보였다( $\beta = .312, p = .003$ ). 전체 모형은 통계적으로 유의하였으며 ( $F(2, 65) = 66.33, p < .001$ ), 설명력은  $Adj. R^2 = .661$ 로, 두 변인이 AI융합교육 역량의 약 66.1%를 설명하는 것으로 나타났다. 이는 TPACK과 TAM이 교사의 AI융합교육 역량 형성에 핵심적인 예측 요인으로 작용함을 시사한다.

Table 23. Multiple Regression of TPACK, TAM Sub-Factors on AICEC

Predictor	B	SE	$\beta$	t	p
(Intercept)	4.185	0.0505	—	82.89	<.001***
CK	0.213	0.1479	0.177	1.44	.155
TK	0.312	0.1285	0.284	2.43	.018*
PCK	0.195	0.1159	0.187	1.68	.098
TPK	-0.324	0.1830	-0.287	-1.77	.082
TCK	0.002	0.1518	0.001	0.01	.990
TPCK	0.346	0.1398	0.267	2.48	.016*
PEOU	0.213	0.1089	0.241	1.95	.056
PU	0.001	0.1137	0.007	0.01	.994
Attitude	-0.154	0.1704	-0.144	-0.91	.367
BI	0.273	0.1645	0.263	1.65	.103
F(df), p	16.47(10, 57), p < .001				
Adj. R2	.698				

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

※ Dependent variable: AI Convergence Education Competency.

Table 23과 같이 다중회귀분석을 통해 TAM과 TPACK의 하위 요인들이 교사의 AI융합교육 역량에 미치는 영향을 분석한 결과, 전체 모형은 통계적으로 유의미하였으며 ( $F(10, 57) = 16.47, p < .001$ ), 설명력은  $Adj. R^2$ 는 .698로 나타나 본 모형이 AI융합교육 역량을 약 70% 설명함을 보여주었다.

개별 예측 변수 중에서는 테크놀로지 지식인 TK( $\beta = .284, p = .018$ )과 테크놀로지 교수내용 지식인 TPCK( $\beta = .267, p = .016$ )이 AI융합교육 역량에 유의미한 정(+)의 영향을 미치는 것으로 나타났다. 이는 교사가 AI 관련 기술에 대한 지식과 이를 교수 설계에 통합할 수 있는 능력을 갖추는 것이 AI융합교육 역량 향상에 핵심적인 요소임을 시사한다. 참고로 여기에서 TPCK는 TPACK 프레임워크의 하위요소로서의 테크놀로지 교수내용 지식을 의미한다.

한편, 내용 지식인 CK, 교수내용 지식인 PCK, 테크놀로지 교수법적 지식인 TPK와 TAM의 행동 의도(BI) 및 인지된 사용 용이성(PEOU)은 유의미하지 않았지만 상대적으로 높은 표준화 계수( $\beta$ )를 보여 가능성을 시사하였다. 반면, 인지된 유용성(PU)은 낮은 표준화 회귀계수를 보여, TAM 이론에서의 핵심 구성요소임에도 불구하고 본 연구 모형에서

는 AI융합교육 역량을 설명하는 데에 상대적으로 제한된 역할을 하는 것으로 나타났다. 이는 교육 현장에서 교사들이 기술의 '쓸모'보다는 '사용 가능성'에 더 민감하게 반응하고 있다는 것으로 해석된다.

이러한 결과는 AI융합교육 역량을 신장하기 위해 단순한 태도 변화나 기술 도입을 넘어, 실제 교수 맥락에서 통합적으로 활용할 수 있는 실질적인 기술 및 설계 역량을 강화하는 것이 필요함을 나타낸다.

#### 4.3.3 구조방정식 모형 분석 결과

TPACK과 TAM이 AICEC에 미치는 영향을 검증하기 위해 구조방정식 모형 분석을 실시하였다. 분석은 잠재변수를 활용한 확인적 요인분석(CFA)과 구조모형 경로 분석을 기반으로 수행되었다.

구조모형은 TPACK-TAM 결합 틀을 토대로, 표본 규모 대비 모수 수의 균형을 고려한 핵심 경로 중심의 최소표현(parsimonious specification)을 채택하였다. 구체적으로 TPACK의 TK와 TPCK를 각각 교사의 AI 도구 친숙성과 수업 맥락에서의 기술, 내용, 교수의 통합지식으로 보고, 이들이 인지된 사용 용이성(PEOU)과 AI융합교육 역량(AICEC)의 변동을 설명하는 근접 요인(proximal determinants)으로 설정하였다. TAM에서는 PEOU→사용의도(BI)의 핵심 경로와 AICEC→BI 경로를 포함하였다. 이는 디지털 도구의 용이성 지각이 실제 사용의도로 직결되고, 교사의 역량 수준이 높을수록 적용 의도가 강화된다는 이론적 정합성과 선행연구의 축약형 경로를 반영한 것이다. 한편 인지된 유용성(PU)과 태도(Attitude)는 개념적 중첩과 표본 대비 과모수화 가능성을 고려해 본 분석에서 제외하였으며, 이로 인해 TAM의 완전 경로를 구현하지 못했다는 제한을 사전에 명시한다. 따라서 본 모형은 이론의 유기성을 유지하되, 표본 제약 하에서 핵심 인과사슬을 점검하려는 이론 정합적 축약모형으로 이해되어야 한다.

AI융합교육 역량(AICEC)은 각 하위 요소(예: AIL, AIED, AICEL, AICEI)의 관측값을평균하여 구성한 합성지표(composite index)로 운영하였다. 이 방식은 표본 규모 대비 모수 수를 줄여 모형을 간결하게 유지하는 장점이 있으나, 잠재변수 측정모형과 달리 측정 오차를 분리 및 추정하지 못하고 모든 지표에 동일 가중치를 부여한다는 제약이 있다. 따라서 AICEC 관련 경로계수는 감쇄 가능성을 내포하므로 해석을 보수적으로 제한하였다. 이상적으로는 네 하위 차원을 지표로 하는 반영적 잠재변수로 모형화하는 것이 타당하나, 이는 표본 규모와 복잡도를 고려하여 후속 연구에서 재검증할 계획이다.

이와 같은 모형 설계를 통해, 본 연구는 기술수용과 교수 설계 능력이라는 이론적 기반이 교사의 AI융합교육 실행 역량에 어떠한 영향을 미치는지를 통합적으로 검증하고자 하였다. 또한, 잠재변수 수를 제한하고 경로를 간소화함으로써 모델의 자유도를 확보하고, 구조모형의 적합도를 향상시키는 실증적 타당성도 함께 고려하였다.

**Table 24.** Standardized Path Coefficients and Significance in the Structural Equation Model

Path	$\beta$	SE	z	p
TK → PEOU	0.350	0.221	1.76	.078
TPCK → PEOU	0.426	0.176	2.27	.023*
PEOU → BI	0.782	0.129	6.55	<.001***
TPCK → AICEC	0.464	0.107	4.15	<.001***
BI → AICEC	0.494	0.108	4.34	<.001***

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

Table 24는 본 연구에서 설정한 구조방정식 모형 내 주요 경로에 대한 표준화된 회귀계수( $\beta$ ) 및 통계적 유의성을 제시한 것이다. 분석 결과, 대부분의 경로가 통계적으로 유의미한 영향을 보였다. 우선, TPCK → PEOU 경로는  $\beta = .426$ ,  $p = .023$ 으로 유의미하게 나타났으며, TK → PEOU 경로는  $p = .078$ 로 10% 수준에서 유의성이 근접하였다.

PEOU는 BI에 매우 강한 영향을 미쳤으며( $\beta = .762$ ,  $p < .001$ ), 이는 TAM의 핵심 경로를 뒷받침하는 결과이다. 또한 TPCK와 BI 모두 AI융합교육 역량(AICEC)에 직접적으로 유의미한 영향을 미치는 것으로 나타났다( $\beta = .604$ ,  $\beta = .494$ , 모두  $p < .001$ ).

이러한 결과는 TPACK의 TPCK 구성요소와 TAM의 PEOU 및 BI 요소가 AI융합교육 역량 형성에 있어 직접적 및 간접적 경로로 작용함을 시사한다. 특히, 교사의 기술-내용-교수지식 통합 능력(TPCK)과 행동의도는 역량 향상의 주요 촉진 요인으로 기능함을 확인할 수 있다.

**Table 25.** Fit Indices for the Structural Equation Model

Fit Index	Value	Recommended Values
$\chi^2$ (df = 84)	147.00	Nonsignificant
p	< .001	$p > .05$
CFI(Comparative Fit Index)	0.943	$\geq .90$
TLI(Tucker-Lewis Index)	0.929	$\geq .90$
SRMR(Standardized Root Mean Square Residual)	0.066	$\leq .08$
RMSEA(Root Mean Square Error of Approximation)	0.105	$\leq .08$ (ideal) $\leq .10$ (acceptable)
90% CI(confidence interval for RMSEA)	[0.076, 0.133]	-

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

Table 25에 본 구조모형의 적합도 지표를 나타내었다.  $\chi^2(84) = 147.00$ ,  $p < .001$ 로 모형의 절대적 적합도는 유의하지 않았으나, 이는 표본 크기의 민감으로 해석된다. 따라서 수용 가능한 모형 적합도를 보기 위해 CFI, TLI, SRMR, RMSEA 등의 대안 지표를 중심으로 해석하였다. CFI(.943)와 TLI(.929)는 기준치(.90 이상)를 만족하며, SRMR(.066)은 .08 이하로 양호한 적합도를 보였다. RMSEA는 .105로 다소 높은 수준이나, .10 이내의 허용 한계에 근접하였고,

90% 신뢰구간은 [.076, .133]으로 하한값은 기준치에 부합하였다. 전체적으로 해당 모형은 통계적 적합성을 수용 가능한 수준에서 확보한 것으로 판단된다.

**Table 26.** Explained Variance (R2) of Endogenous Variables in the Structural Equation Model

	PEOU	BI	AICEC
R2	.535	.611	.709

Note. R<sup>2</sup> represents the proportion of variance explained in each endogenous latent variable by its predictor(s) in the model.

Table 26은 구조방정식 모형에서 각 내생변수에 대한 설명력을 제시한 것이다. PEOU의 설명력은 .535로 나타났으며, 이는 TK와 TPCK에 의해 설명되는 분산의 비율을 의미한다. BI의 경우, PEOU에 의해 .611이 설명되었고, AI융합교육 역량(AICEC)은 TPCK와 BI에 의해 총 .709의 설명력을 나타냈다. 이는 전체적으로 제안된 모형이 교사의 인지적 수용 및 실행 역량을 설명하는 데 있어서 상당히 높은 수준의 설명력을 지니고 있음을 시사한다.

**Table 27.** Standardized Path Coefficients and Significance in the Structural Equation Model

Path	Direct Effect( $\beta$ )	Indirect Effect( $\beta$ )	Total Effect( $\beta$ )
TK → PEOU	.350	—	.350
TPCK → PEOU	.426*	—	.426*
PEOU → BI	.782***	—	.782***
TPCK → BI	—	.333†	.333†
TK → BI	—	.274†	.274†
TPCK → AICEC	.464***	.245*	.709***
BI → AICEC	.494***	—	.494***
TK → AICEC	—	.153	.153
PEOU → AICEC	—	.393***	.393***

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

Note. † = calculated manually by chaining standardized coefficients (e.g., TPCK → PEOU → BI). blank (—) indicates no direct/indirect path specified in the model.

Table 27은 본 구조방정식 모형에서 주요 경로에 대한 직접효과, 간접효과, 총효과를 통합적으로 정리한 것이다. 분석 결과, TPCK는 AI융합교육 역량(AICEC)에 대해 직접효과( $\beta = .464$ ,  $p < .001$ )뿐 아니라, PEOU와 BI를 매개로 한 간접효과( $\beta = .245$ )까지 포함하여 총효과가 .709로 매우 높은 수준으로 나타났다. 또한 TK는 AICEC에 대한 직접효과는 없으나, PEOU → BI → AICEC의 경로를 거치는 간접효과( $\beta = .153$ )를 통해 의미 있는 영향력을 보였다. PEOU와 BI 역시 각각 .393, .494의 총효과를 보이며 AICEC 형성에 핵심적인 매개 변인으로 작용하고 있음을 확인할 수 있었다.

이러한 결과는 TPACK과 TAM 요소들이 직접적 경로와 함께 간접적 구조적 경로를 통해 AI융합교육 역량에 복합적

으로 영향을 미친다는 점을 시사한다. 특히 TPCK의 총효과가 가장 크고, TK도 간접경로를 통해 기여하고 있어, 교사의 기술적 이해와 교수지식 통합 능력이 AI융합교육 실천역량의 중요한 기반임을 뒷받침한다.




Figure 1. Integrated but Parsimonious TAM-TPACK Model (AICEC treated as a composite index)

Note. AICEC is modeled as an observed composite (rectangle). Core paths retained: TK, TPCK → PEOU; PEOU → BI; AICEC → BI. PU and Attitude are part of the canonical TAM chain but were omitted here due to sample-size and collinearity considerations; see text for theoretical justification and limitations.

Figure 1은 본 연구에서 설정한 구조방정식 모형의 경로 구조를 시각적으로 제시한 것이다. TK, TPCK, PEOU, BI 등의 잠재변수가 AI융합교육 역량(AICEC)에 미치는 영향을 분석하였다. 그림 속 실선은 통계적으로 유의미한 경로 ( $p < .05$ )를, 점선은 유의하지 않은 경로를 나타낸다. 각 경로 옆의 숫자는 표준화 경로계수( $\beta$ )를 의미하며, 각 잠재변수는 복수의 관측변수를 통해 측정되었다.

TPCK는 PEOU와 AICEC 모두에 직접적인 영향을 미치며, PEOU와 BI를 매개로 간접적인 영향도 나타내고 있다. TK는 직접적으로 AICEC에 영향을 미치지 않았으나, PEOU 및 BI를 경유하여 AICEC에 유의미한 간접효과를 갖는 것으로 나타났다. 특히 BI와 PEOU는 AICEC에 대한 강한 매개 경로로 작용하고 있으며, 이는 TAM 기반 모형의 인과 구조를 뒷받침한다.

이러한 구조방정식 모형 분석 결과는 TPACK과 TAM이 교사의 AI융합교육 실천 역량을 설명하는 데 이론적 타당성과 실증적 적합성을 모두 갖추고 있으며, 특히 TPCK와 BI가 핵심 매개 및 예측 요인으로 기능함을 보여준다. 단, 여기에서는 TPACK-TAM 결합 이론의 핵심 인과사슬을 축약 형태로 점검한 것인바, PU와 Attitude의 비포함, AICEC의 합성지표 처리는 결과 해석의 범위를 제한한다. 따라서 여기에서의 결론은 핵심 경로의 탐색적 검증으로 이해되어야 하며, 완전 TAM 경로 및 잠재변수 기반 AICEC을 포함하는 정교한 모형 검증은 표본 확장과 함께 후속 연구에서 재검증되어야 한다.

4.4 교사 배경 변인 및 TPACK, TAM이 AI융합교육 역

량에 미치는 영향

4.4.1 위계적 회귀 분석 결과

교사의 AI융합교육 역량(AICEC)에 영향을 미치는 배경 요인, TPACK 요인, TAM 요인의 상대적 설명력을 단계적으로 파악하고, 중요한 결정 요인을 도출하기 위해 위계적 회귀 분석(hierarchical multiple regression analysis)을 실시하였다. 이 분석은 변인의 이론적 중요도와 선행 연구 및 앞선 분석 결과에 기반하여, 세 단계로 구분하여 독립변수를 순차적으로 투입하는 방식으로 설계되었다.

Table 28. Hierarchical Regression Analysis Predicting AICEC

Predictor	Model 1 $\beta$	Model 2 $\beta$	Model 3 $\beta$
Subject (STEM vs Humanities and Social Science)	.560*	.393†	.377†
Subject (Elementary vs Humanities and Social Science)	.206	.139	.162
Number of Implemented Lessons	.026	.026	.037
Duration of Study	.352**	.266*	.233†
Mentoring/Consulting Level	.263*	.168†	.174†
Self-Directed Learning (Yes)	.141	.088	.072
TK		.107	.043
TPCK		.462***	.355**
PEOU			.192
BI			.111
R <sup>2</sup>	.426	.677	.716
Adjusted R <sup>2</sup>	.379	.637	.668
$\Delta R^2$	-	.251***	.039†
F (df)	7.30*** (6,59)	17.17*** (8,57)	13.86*** (10,55)

\*  $p < .05$ , \*\*  $p < .01$ , \*\*\*  $p < .001$ , †  $p < .10$

Note. The reference category for subject area is Humanities and Social Sciences. Self-directed learning is coded as 1 = Yes, 0 = No.

Table 28과 같이 1단계(Model 1)에서는 교사의 배경 변인을 중심으로, 담당 교과 계열, AI융합교육 수업을 실천한 차시 수, 멘토링 참여 수준, 대학원 재학 기간, 자기주도 학습 경험 여부 등을 포함하였다. 담당 교과 계열은 3 집단으로(초등계열, 이공계열 과목, 인문계열 과목)로 구성하였으며, 인문계열 교사를 기준(reference group)으로 하여, 이공계열 및 초등계열 교사를 더미변수로 처리하였다. 이는 앞선 교사의 담당 교과 계열에 따른 AI융합교육 역량의 차이를 일원분산분석(One-way ANOVA)을 실시한 결과와 Tukey HSD 사후 검정 결과를 반영한 결과이다.

2단계(Model 2)에서는 TPACK 요인으로써, TK와 TPCK를 포함하였다. 이 역시 앞선 분석 결과를 중심으로, 교사의 실천적 교육 역량이 배경 변인을 넘어서 AI융합교육 실행 역량에 어떠한 추가적 설명력을 가지는지를 확인하기

위함이다.

3단계(Model 3)에서는 TAM 요인으로써, PEOU와 BI를 포함하였다. 이 또한 앞선 분석 결과를 토대로 설정되었으며, 기술에 대한 인지·정의적 요인의 기여도를 종합적으로 검토하고자 하였다.

분석 결과는 Table 28과 같다. 모델 1의 전체 설명력은  $R^2 = .426(F(6,59) = 7.30, p < .001)$ 으로 나타났으며, 대학원 재학 기간( $\beta = .352, p < .01$ )과 멘토링 참여 수준( $\beta = .263, p < .05$ ), 그리고 이과계열 교과 담당 교사( $\beta = .560, p < .05$ )가 유의미한 예측 변인으로 확인되었다.

Model 2의 전체 설명력은  $R^2 = .677$ 로 증가하였고, 설명력 변화량은  $\Delta R^2 = .251(p < .001)$ 로 유의하였다. 특히 TPCK( $\beta = .462, p < .001$ )는 가장 강력한 예측 요인으로 나타났으며, 이는 교사의 통합 교수지식이 AI융합교육 역량 형성에 핵심적인 영향을 미침을 시사한다.

Model 3의 전체 설명력은  $R^2 = .716(F(10,55) = 13.96, p < .001)$ 으로 증가하였으며, 설명력의 추가 증가는  $\Delta R^2 = .039(p < .05)$ 로 나타났다. 이 단계에서 TPCK는 여전히 유의한 영향력을 유지하였으며( $\beta = .355, p < .01$ ), PEOU는 유의성 경계선( $\beta = .192, p = .105$ )에 있었고, BI는 통계적으로 유의하지 않은 것으로 나타났다( $\beta = .111, p = .332$ ).

이러한 결과는 교사의 AI융합교육 역량은 기본적인 배경 특성뿐 아니라, TPACK과 같은 교수설계 역량과 기술 수용에 대한 인식적 요인이 함께 작용하는 복합적 구조에 의해 설명될 수 있음을 의미한다. 특히 TPCK는 모든 모델에서 일관되게 유의한 영향력을 보이며, 교사의 테크놀로지 교수 내용 지식이 AI융합교육 실천에 있어 핵심 결정 요인으로 기능함을 보여준다.

이후 교사의 배경 변인에 따른 다중집단 구조방정식 분석을 시도하였으나, 각 배경 변인에 따른 구분 집단 중 하나 이상의 표본 수가 잠재변수 기반 분석을 위한 최소 기준( $n \geq 30$ )을 충족하지 못해 분석을 수행하지 못하였다. 이에 따라 대안적으로 잠재적 프로파일 분석(latent profile analysis, LPA)을 수행하였다.

#### 4.4.2 잠재적 프로파일 분석 결과

잠재적 프로파일 분석을 통해 교사의 AI융합교육 역량 및 관련 변인을 종합적으로 고려하여, 교사 집단 내에 존재할 수 있는 이질적인 하위 집단(프로파일)을 탐색적으로 도출하고자 하였다.

잠재적 프로파일 분석(latent profile analysis, LPA)은 연속형 변인에 기반하여 교사들을 잠재적으로 유사한 응답 특성을 지닌 하위 집단으로 분류하는 통계적 접근이다. LPA는 거리 기반 군집분석과 달리, 확률 모형에 기반한 분류 기법으로 개별 사례가 각 잠재집단에 속할 확률을 추정하며, 모형의 적합도 지표(AIC, BIC, Entropy 등)를 통해 최적의 프로파일 수를 결정할 수 있다는 장점을 가진다[33].

분석에 사용된 주요 변수는 다음과 같다. 첫째, 교사

의 AI융합교육 역량을 구성하는 네 가지 하위 요인(AIL, AIED, AICEL, AICEI)을 평균값으로 반영하였다. 둘째, TPACK 및 TAM의 TK, TPCK, PEOU, BI 요인을 포함하였다. 셋째, 교사의 배경 변인 중, 실제 수업 실천 경험을 반영하는 AI융합교육 수업 차시 수, 멘토링 참여 수준, 그리고 자기주도 학습 경험 여부와 같은 교사 배경 변인을 포함하여, 인지적·행동적·경험적 요인을 종합적으로 반영하였다. 교사의 배경 변인 중 담당 교과 계열은 범주형 변수이므로 연속형 변수 기반의 LPA에는 적합하지 않아 제외하였고, 대학원 재학 기간의 경우 순서형 변수이긴 하지만 실제 교육경험 반영과 연속성 측면에서 약하기 때문에 제외하였다.

LPA 모형의 잠재 집단 수 결정은 통계적 기준과 해석적 기준을 종합적으로 고려하여 수행하였다. 우선, 잠재 집단의 수를 3개, 4개, 5개로 설정하여 분석한 뒤, AIC(Akaike Information Criterion) 및 조정된 BIC(Bayesian Information Criterion) 값을 산출하여 모형의 상대적 적합도를 비교하였다. 또한 각 모형의 분류 정확도를 나타내는 Entropy 값을 함께 산출하여 해석 가능성과 집단 간 명확성을 판단하였다.

이러한 절차를 바탕으로 통계적 지표와 해석의 타당성을 종합적으로 고려한 결과, 본 연구에서는 3개 잠재 집단 프로파일이 가장 적절한 것으로 판단되어 최종 분석 모형으로 채택하였다.

Table 29. Fit Indices for the 3-Profile Latent Profile Mode

Model	AIC	BIC	Entropy	Silhouette
3-Profile Solution	832.40	1342.59	0.001	0.331

Table 29는 3개 프로파일 기반 잠재 프로파일 분석의 모형 적합도 지표를 제시한 것이다. AIC와 BIC는 각각 832.40, 1342.59로 나타났으며, 실루엣 점수는 0.331로 프로파일 간의 분리도가 비교적 양호한 수준임을 시사한다. 그러나 Entropy 값이 통상적 기준치( $> .80$ )보다 현저히 낮다. 이는 개별 사례의 프로파일 귀속에 상당한 불확실성이 존재할 수 있다. 따라서 프로파일 간 경계가 뚜렷하기보다 연속선상에 분포할 가능성을 시사하며, 해석 시 과도한 유형화를 지양할 필요가 있음을 나타낸다.

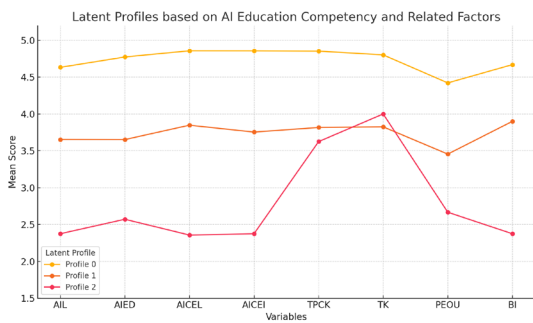
도출된 잠재 프로파일 간에 교사의 배경 변인에 따라 차이가 나타나는지를 확인하기 위해 교차분석( $\chi^2$  분석)을 실시하였다. 분석 대상 변수는 AI융합교육 수업 실천 횟수(범주화), 멘토링 참여 수준, 그리고 자기주도 학습 경험 여부였다.

**Table 30.** Chi-square Tests for Differences in Background Variables across Latent Profiles

Variable	$\chi^2$	df	p
Number of Implemented Lessons	17.462	4	.0016**
Mentoring/Consulting Involvement Level	15.484	6	.0168*
Self-Directed Learning	20.430	2	< .001***

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

분석 결과, Table 30과 같이 세 변수 모두 잠재 프로파일 간 분포에 통계적으로 유의한 차이가 있는 것으로 나타났다. 자기주도 학습 경험 여부는  $\chi^2 = 20.43(df = 2, p < .001)$ 로, 세 프로파일 간 가장 명확한 차이를 보였다. 또한 수업 실천 횟수( $\chi^2 = 17.46, p = .0016$ ), 멘토링 참여 수준( $\chi^2 = 15.48, p = .0168$ )에서도 유의미한 차이가 나타났다



**Figure 2.** Latent Profiles Based On AI Education Competency And Related Factors

Figure 1은 잠재 프로파일 분석을 통해 도출된 세 집단 간에 AICEC의 하위요인 및 TPACK, TAM 요소의 평균값 분포를 시각화한 것이다. 전반적으로 Profile 0은 모든 변수에서 가장 높은 점수를 유지하고 있으며, 특히 AIL, AIED, AICEL, AICEI 네 가지 AI융합교육 역량 하위요인과 TPCK, TK, BI 항목에서 평균 4.5점 이상을 기록하여 고역량 실천형 교사 집단의 특성을 보여준다.

반면 Profile 2는 AICEC 네 가지 요인과 TAM 요인 (PEOU, BI)에서 모두 평균 2.5 이하의 낮은 점수를 보이며, 역량과 실천 모두에서 낮은 수준의 소극형 집단으로 해석된다. 다만 TK 요인에서는 평균 4.0의 상대적으로 높은 점수를 보여, 기술 활용 능력은 있으나 실제 교육 실천이나 TPCK으로의 전이가 이루어지지 않은 상태로 볼 수 있다.

Profile 1은 대부분의 항목에서 중간 수준의 점수를 유지하고 있으며, 특히 TPCK, BI, AICEL에서 점진적인 상승 추세를 보인다. 이는 해당 교사들이 중간 수준의 인식과 역량을 바탕으로 향후 실천 가능성과 성장 여지를 지닌 집단임을 시사한다.

Table 31에는 3개 잠재 프로파일에 따른 교사들의 AI융합교육 역량, TPACK 및 TAM 요인, 실천 경험, 자기주도 학습 및 멘토링 참여 수준의 평균 및 표준편차를 제시했다.

**Table 31.** Descriptive Statistics of Each Latent Profile Group (M ± SD)

Variable	Profile 0	Profile 1	Profile 2
AIL	4.63 ± 0.50	3.65 ± 0.47	2.38 ± 0.18
AIED	4.77 ± 0.39	3.65 ± 0.55	2.57 ± 0.20
AICEL	4.86 ± 0.29	3.85 ± 0.44	2.36 ± 0.51
AICEI	4.86 ± 0.30	3.75 ± 0.49	2.38 ± 0.53
TPCK	4.85 ± 0.29	3.82 ± 0.48	3.62 ± 1.59
TK	4.80 ± 0.28	3.82 ± 0.57	4.00 ± 0.00
PEOU	4.42 ± 0.68	3.46 ± 0.60	2.67 ± 0.47
BI	4.67 ± 0.46	3.90 ± 0.60	2.38 ± 0.53
Implemented Lessons Hour	40.79 ± 70.97	7.80 ± 8.92	0.00 ± 0.00
Self-Directed Learning	1.0 ± 0.0	0.77 ± 0.43	0.0 ± 0.0
Mentoring/Consulting Level	1.53 ± 1.11	1.00 ± 0.74	0.00 ± 0.00

각 프로파일은 교사들의 인식적 특성, 수업 실천 경험, 태도적 요인 및 배경 변인에 따라 상이한 특성을 보였다.

Profile 0은 모든 변수에서 평균적으로 가장 높은 점수를 보인 집단으로, 특히 AI융합교육 역량 및 TPACK, TAM 요인의 평균이 모두 4.5 이상이며, 실천 경험 또한 평균 40.8 차시로 가장 높았다. 이 집단은 자기주도 학습 경험과 멘토링 참여 수준 또한 높게 나타나, AI융합교육을 실제 교육 현장에서 적극적으로 실천하고 있는 “실천형 고역량 교사” 집단으로 해석할 수 있다.

Profile 1은 전반적인 변수에서 중간 수준의 점수를 보였으며, 실천 차시 수는 평균 7.8회로 낮은 편이었으나, 자기주도 학습 경험은 일부 존재하였다. TPACK 및 TAM 요인에서도 중간 정도의 인식과 태도를 보이는 것으로 나타나, AI융합교육에 대한 인식은 갖추었지만 실천이 상대적으로 부족한 “잠재 성장 가능 교사” 유형으로 해석된다.

Profile 2는 거의 모든 변수에서 가장 낮은 점수를 보였으며, 실천 경험은 전혀 없었고, 자기주도 학습 및 멘토링 참여 경험 또한 매우 낮은 수준으로 나타났다. 특히 AI융합교육 역량 하위요인의 평균이 2점대 초반에 불과하였으며, 기술 수용에 대한 태도도 낮은 편으로, “소극형 저역량 교사” 유형으로 분류할 수 있다.

이와 같은 분석을 통해 도출된 세 가지 교사 집단의 교사 특성과 제안된 유형 명칭은 Table 32와 같다. Profile 0은 전체 교사의 약 51.5%를 차지하며, AI융합교육 역량 (AICEC), TPACK, TAM 요인 전반에서 매우 높은 평균값을 나타냈다. 해당 집단은 실제 수업 실천 경험도 가장 많고, 멘토링 참여와 자기주도 학습 경험 또한 활발하여 ‘고역량 실천형 교사(High-capacity Practice-Oriented Teachers)’로 명명했다.

Profile 1은 전체의 44.1%로, 대부분의 변수에서 중간 수준의 점수를 나타내며 일부 수업 실천과 자기주도 학습 경험을 보유하고 있다. 이는 일정 수준의 인지적 역량과 태도를 기반으로 성장 가능성을 내포한 집단으로, ‘성장잠재형

교사(Emerging Growth-Potential Group)’로 분류했다.

반면 Profile 2는 전체의 5.9%에 해당하며, AICEC 및 TAM 요인은 매우 낮고 수업 실천 및 자기주도 학습 경험이 전무하였다. 다만 기술지식(TK)만이 비교적 높은 수준을 보여, AI교육에 대한 기초 기술은 있으나 실천적 전이가 이루어지지 않은 상태로 해석된다. 이에 따라 이 집단은 ‘소극형 기술중심 교사(Low-engagement, Technology-Only Teachers)’로 명명했다.

그러나 Table 32의 나타난 것과 같이 Profile 2의 사례 수가 매우 소수여서 통계적 안정성이 떨어질 수 있으므로, 본 결과는 참고적 의미로 이해되어야 하며 후속 연구에서 표본의 확장과 재검증이 필요함이 시사된다

**Table 32.** Summary of Latent Profiles of Teachers Based on AI Education Competency

Latent Profile	N(%)	Profile Summary	Suggested Label
Profile 0	34 (50.0)	High scores across all variables (AICEC, TPACK, TAM); high number of implemented lessons; active mentoring and self-directed learning	High-capacity Practice-Oriented Teachers
Profile 1	30 (44.1)	Moderate scores on most variables; some implementation experience; partially engaged in self-directed learning	Emerging Growth-Potential Group
Profile 2	4 (5.9)	Low AICEC and TAM scores; no implementation or self-directed learning; only TK (technical knowledge) was relatively high	Low-engagement, Technology-Only Teachers

본 연구에서 도출한 세 가지 교사 유형은 AI융합교육 역량의 이질적 양상을 탐색적으로 조명한다는 점에서 의의가 있으나, 매우 낮은 Entropy 값과 소수 집단의 존재는 분류의 정확도와 재현성에 구조적 한계를 남긴다. 이에 따라 프로파일별 평균 비교나 라벨링에 기반한 강한 인과적·정책적 해석은 자제해야 하며, 본 연구의 프로파일 해석은 탐색적 제안으로 한정하는 것이 타당하다. 특히 사례 수가 극히 적은 프로파일에 대해서는 정형화된 특성 규정이나 일반화를 피하고, 유사 특성을 보이는 교사군의 가능성을 가설적 수준으로 제시하는 데 그쳤다. 향후 연구에서 표본 규모의 확대, 지표 구성의 재점검, 및 다양한 표집 맥락에서의 재현 분석을 통해 분류의 안정성과 실천적 타당성을 확인할 필요가 있다.

## 5. 결론 및 제언

본 연구는 교사의 AI융합교육 역량에 영향을 미치는 주요 요인을 종합적으로 분석하고, 이를 기반으로 교사 집단 내의 이질성을 탐색하기 위해 잠재 프로파일 분석(latent profile analysis, LPA)을 실시하였다. 또한, AI융합교육

역량(AICEC)을 중심으로 한 구조방정식 모형 분석과 잠재 프로파일 분석을 연계함으로써, 기존 연구에서 충분히 조명되지 않았던 교사 역량의 구조적 형성과 집단적 다양성을 실증적으로 탐색하였다.

연구 결과, TPACK과 TAM 요인은 AI융합교육 역량에 유의미한 영향을 미치며, 특히 TPACK는 가장 강력한 예측 요인으로 작용하였다. 행동의도(BI)와 지각된 사용 용이성(PEOU)은 AI융합교육 역량에 간접 및 직접 경로 모두에서 유의미한 영향을 나타내어, AI 기술을 활용한 교육 실행에 있어 교사의 태도 및 인식의 중요성을 입증하였다. 특히 테크놀로지 지식(TK)은 직접적인 영향력은 낮았으나, PEOU와 BI를 매개로 한 간접 경로를 통해 AI융합교육 역량에 기여함으로써 기술 중심 지식의 기반 위에 수업 실행으로 연결되는 전환 과정이 중요함을 시사하였다.

배경 변인 분석 결과에 따르면, 성별, 연령, 교직 경력, 학교급 등의 일반 인구통계학적 변인은 AI융합교육 역량에 유의한 차이를 보이지 않았으나, 실제 AI융합수업 실행 경험, 멘토링 및 컨설팅 참여 수준, 자기주도 학습 경험 유무는 역량에 유의한 영향을 미치는 핵심 요인으로 나타났다. 이는 역량 함양에 있어 교사의 행위 기반 경험과 실천적 학습이 보다 본질적인 요소임을 보여주는 결과로, 인식이나 태도만으로는 충분치 않음을 의미한다.

잠재 프로파일 분석 결과, 교사는 크게 세 집단으로 유형화되었다. 첫째, ‘고역량 실천형 집단(High-capacity Practice-Oriented Group)’은 높은 수준의 지적 역량과 함께 활발한 수업 실행 및 멘토링 제공 경험, 자기주도 학습 태도를 갖춘 교사들로 구성되었다. 둘째, ‘성장잠재형 집단(Growth-potential Group)’은 역량 수준은 중간이나 향후 발전 가능성이 높은 교사들로, 일정 수준의 인식과 학습 참여는 있으나 실천 경험은 비교적 낮은 특징을 보였다. 셋째, ‘소극형 기술중심 집단(Low-engagement, Technology-reliant Group)’은 기술적 지식은 보유하고 있으나 교육 실행 및 태도 측면에서 소극적인 특성을 지닌 집단이었다. 이들 세 집단은 역량 구성 요인(TPACK, TAM), 수업 경험, 학습 태도 측면에서 유의미한 차이를 보이며, AI융합교육 실천과 확산을 위한 맞춤형 전략 마련의 필요성을 강조할 수 있다. 그러나 본 연구의 잠재 프로파일 분석은 낮은 Entropy와 소수 집단으로 인해 분류의 확실성이 충분히 담보되지 못했다는 점을 명확히 한다. 이에 따라 프로파일을 전제로 한 실천적 권고는 탐색적 권고로만 이해되어야 하며, 일반화는 보수적으로 이루어져야 한다.

이상의 결과를 바탕으로 다음과 같은 제언을 제시한다.

첫째, TPACK 중심의 실천 기반 교사 연수가 강화되어야 한다. 단순한 이론 전달이나 기술 사용법 중심의 연수를 넘어, 실제 교과 수업에 적용 가능한 통합적 수업 설계 및 실행 중심 연수가 요구된다. 이를 위해 AI융합수업 예시 공유, 공동 수업 설계, 피드백 및 재설계 중심의 참여형 연수 프로그램이 마련되어야 한다.

둘째, 자기주도적 학습을 촉진할 수 있는 생태계 조성이

필요하다. 공식 연수 외 시간에도 교사가 자발적으로 AI융합교육 역량을 함양할 수 있도록, 온라인 학습 콘텐츠, AI 교육 자료 아카이브, 교사 커뮤니티 운영 등 비형식 학습 자원에 대한 접근성과 활용성을 강화해야 한다.

또한, 본 연구의 잠재 프로파일 분석에 한계가 있음에도 교사 집단의 유형에 따라 다음과 같은 전략을 시사하고자 한다. 첫째, '고역량 실천형'교사는 TPCK와 AICEC 수준이 상대적으로 높고 실제 적용 경험이 풍부하므로, 단순 연수 참여자가 아니라 지식 확산의 허브로 배치해야 한다. 즉, 멘토 및 컨설턴트로 공식화 하고, 교사 연구회 리딩, 학교 간 순환 컨설팅 등에 배치하고, 이에 대한 정당한 보상(시수, 수당, 가점 등)을 제공하여 이들의 전문성을 널리 확산할 필요가 있다.

둘째, '성장잠재형' 교사는 기초 역량 및 태도는 확보했으나 실천의 간극이 존재한다. 따라서 동료 교사와 교사 동아리 활동 및 수업 수업 나눔, 동료 장학 등의 기회와 수업 실행 부담을 낮출 수 있는 수업 템플릿을 제공하는 등의 지원이 필요로 된다.

셋째, '소극형 기술중심' 교사는 집단은 TK(기술지식)는 비교적 높으나 TPCK·실천 역량이 낮은 특성이므로, 기술 기능 설명을 최소화하고 수업 목표-평가-활동-기술의 정렬을 강조한 TPCK 연계 템플릿을 제공하며, 학습결손 보완·형성평가 자동화 등 수업 가치 시나리오를 우선 제시하고, 10-15분 규모의 저위험 체험 과제로 초기 성공 경험을 설계한 뒤 공동 수업·공동 루브릭을 통해 단계적으로 자율 설계로 이행하도록 지원할 필요가 있다.

학교 및 지역교육청 차원에서는 세 유형을 축으로 한 지원 체계를 구축하고, 연 1~2회 정도의 멘토링-브릿지 워크숍 매칭을 운영하여 수업 설계 루브릭, 적용 빈도, 교사 사용 의도 변화, 학생 산출물-참여도 등을 간명한 대시보드로 모니터링하되, 교사 유형은 고정된 범주가 아니라 맥락과 성장에 따라 이동 가능한 스펙트럼임을 명시하여 지원을 개인화, 가변화 한다면 맞춤형 교사 역량 증진에 기여할 수 있게 될 것이다.

한편, 본 연구의 대상인 AI융합교육 전공 교육대학원생은 일반 교사 집단에 비해 AI 교육에 대한 관심과 동기가 상대적으로 높을 가능성이 크며, 실제로 주요 구성개념의 평균이 전반적으로 높은 수준인 것을 관찰할 수 있었다. 따라서 본 연구에서 분석한 결과는 일반 교사 전체로의 단순 일반화에 분명한 제약이 있다. 그럼에도 불구하고, 본 연구의 주요 관심은 수준치 자체가 아니라 변인 간 관계 구조에 있었으며, 표본 내 분산과 분포의 정규성이 확보된 조건에서 해당 경로를 추정하였다는 점을 고려할 필요가 있다. 더 나아가 유사한 경로·효과는 현직 교사 표본을 대상으로 한 선행연구들에서도 반복적으로 보고되어 왔기에, 관계 구조의 외적 타당성은 일정 부분 지지된다고 해석할 수 있다. 다만, 이러한 해석은 어디까지나 본 연구의 표본 특성을 전제로 한 것이므로, 결과의 해석 범위는 '유사한 특성의 교사군'으로 한정한다.

본 연구는 횡단적 설계를 기반으로 하여 교사 역량 형성과정의 시간적 경향이나 인과성을 완전히 규명하기에는 한계가 있었다. 향후 연구에서는 더 큰 표본의 일반 교사를 대상으로 종단적 연구 설계를 통해 교사의 AI융합교육 역량 변화 경로를 추적하거나, 다집단 구조방정식모형(Multigroup SEM)을 활용하여 지역·교과·학교급 등에 따른 집단 간 차이를 보다 정교하게 비교할 필요가 있다. 이러한 연구는 교사의 역량 변화 과정을 추적함으로써 정책 및 연수 설계에 더욱 실증적인 근거를 제공할 수 있을 것이다.

## 참고문헌

- [1] Velarde, G. (2020). Artificial intelligence and its impact on the Fourth Industrial Revolution: A review. *International Journal of Artificial Intelligence & Applications*, 10(6), 41-48. <https://doi.org/10.5121/ijia.2019.10604>
- [2] Walter, Y. (2024). Embracing the future of Artificial Intelligence in the classroom: The relevance of AI literacy, prompt engineering, and critical thinking in modern education. *International Journal of Educational Technology in Higher Education*, 21 Article 15. <https://doi.org/10.1186/s41239-024-00448-3>
- [3] Ministry of Education. (2020-09-11). 2020-236 Notice of Curriculum Revision: High School Elective Subjects (AI Basics, AI Mathematics) [Official notice]. Ministry of Education, Republic of Korea. <https://www.moe.go.kr/boardCnts/viewRenew.do?boardID=141&lev=0&statusYN=W&s=moe&m=0404&opType=N&boardSeq=81884>
- [4] Ministry of Education. (2022-12-22). 2022-33 Notice: General guidelines and subject curricula for elementary and secondary schools [Official notice]. Ministry of Education, Republic of Korea. <https://www.moe.go.kr/boardCnts/viewRenew.do?boardID=141&boardSeq=93458&lev=0&statusYN=W&page=1&s=moe&m=040401&opType=N>
- [5] Choi, S. (2023). A Study on the Understanding and Solving Tasks of AI Convergence Education. *Industry Convergence Research*, 21(1), 147-157. <https://doi.org/10.22678/JIC.2023.21.1.147>
- [6] Heo, H., & Kang, S. (2023). Teacher competencies for designing artificial intelligence-integrated education. *The Journal of Korean Association of Computer Education*, 26(2), 89-100. <https://doi.org/10.32431/kace.2023.26.2.008>
- [7] Jeong, K., Park, J., Noh, E., & Lee, D. (2025). Development of Teacher Professional Development Program for Enhancing Teachers' Competencies in AI-Convergence Education. *The Journal of Korean Teacher Education*, 42(1), 389-416. <https://doi.org/10.24211/tjkte.2025.42.1.389>
- [8] Ministry of Education. (2023, February 23). *Digital-based educational innovation plan* [Policy document]. Ministry of Education, Republic of Korea. <https://www.moe.go.kr/boardCnts/viewRenew.do?boardID=72769&boardSeq=94551&lev=0&searchType=null&statusYN=W&page=1&s=m>

- oe&m=0315&opType=N
- [9] Hong, S., Yoon, Y., Moon, Y., & Lim, E. (2024). Analysis and evaluation of teacher training for enhancing teachers' AI and digital competence. *Journal of Korean Association for Educational Information and Media*, 30(5), 1421-1446. <https://doi.org/10.15833/KAFEIAM.30.5.1421>
- [10] Mishra, P., & Koehler, M. J. (2006). Technological pedagogical content knowledge: A Framework for Teacher Knowledge. *Teachers College Record: the Voice of Scholarship in Education*, 108(6), 1017-1054. <https://doi.org/10.1111/j.1467-9620.2006.00684.x>
- [11] Ng, D., Leung, J., Chu, S., & Qiao, M. (2021). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, 2, Article 100041. <https://doi.org/10.1016/j.caeai.2021.100041>
- [12] Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319-340. <https://doi.org/10.2307/249008>
- [13] Scherer, R., Siddiq, F., & Tondeur, J. (2019). The Technology Acceptance Model (TAM): A meta-analytic structural equation modeling approach to explaining teachers' adoption of digital technology in education. *Computers & Education*, 128, 13-35. <https://doi.org/10.1016/j.compedu.2018.09.009>
- [14] Son, T., Goo, J., & Ahn, D. (2023). Understanding Elementary School Teachers' Intention to Use Artificial Intelligence in Mathematics Lesson Using TPACK and Technology Acceptance. *Education of Primary School Mathematics*, 26(3), 163-180. <https://doi.org/10.7468/jksmec.2023.26.3.163>
- [15] Lee, K., Yeo, S., Tak, B., Choi, J., Son, T., & Ock, J. (2024). A study on the factors of elementary school teachers' intentions to use AI math learning system: Focusing on the case of TocToc-Math. *The Mathematical Education*, 63(2), 335-350. <https://doi.org/10.7468/mathedu.2024.63.2.335>
- [16] Zhou, T., Tondeur, J., & Howard, S. (2025). AI competency frameworks for teachers: A systematic review. *Proceedings of EdMedia + Innovate Learning*. Barcelona, Spain: Association for the Advancement of Computing in Education (AACE). 648-654. Retrieved from <https://www.learnstechlib.org/p/226198>.
- [17] Miao, F., & Cukurova, M. (2024). *AI competency framework for teachers*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000391104>
- [18] Yi, S., Kim, K. (2024). Development and Validation of an AI Convergence Education Competency Measurement Tool for In-Service Teachers. *The Journal of Korean Association of Computer Education*, 27(4), 159-171. <https://doi.org/10.32431/kace.2024.27.4.012>
- [19] Lee, D., Lee, Y., & Paik, S. (2024). Development and Effect Analysis of Future Problem Solving Program based Informatics, Mathematics, Science Convergence Education Teachers' Training Course using AI for Secondary School Teachers. *The Journal of Korean Association of Computer Education*, 27(5), 1-11. <https://doi.org/10.32431/kace.2024.27.5.001>
- [20] Kang, S., Heo, H., & Jung, H. (2024). A comparative study on middle school teachers' perceptions of artificial intelligence convergence education training. *The Journal of Korean Association of Computer Education*, 27(3), 169-183. <https://doi.org/10.32431/kace.2024.27.3.015>
- [21] Celik, I., Dindar, M., Muukkonen, H., & Järvelä, S. (2022). The promises and challenges of artificial intelligence for teachers: A systematic review of research. *TechTrends*, 66(5), 616-630. <https://doi.org/10.1007/s11528-022-00715-y>
- [22] Bakhadirov, M. (2024). Factors Influencing Teachers' Use of Artificial Intelligence for Instructional Purposes. *IAFOR Journal of Education: Technology in Education*, 12(2), 9-32.
- [23] Kim, K., & Kwon, K. (2023). Exploring the AI competencies of elementary school teachers in South Korea. *Computers and Education: Artificial Intelligence*, 4, 100137. <https://doi.org/10.1016/j.caeai.2023.100137>
- [24] Lim, E., Hong, S., & Lim, C. (2025). Analyzing perceptions and educational needs of elementary school teachers for AI-integrated education. *The Journal of Korean Computer Education*, 28(2), 49-62. <https://doi.org/10.32431/kace.2025.28.2.005>
- [25] Joo, Y., Park, S., & Lim, E. (2018). Factors influencing pre-service teachers' intention to use technology: TPACK, teacher self-efficacy, and technology acceptance model. *Educational Technology & Society*, 21(3), 48-59.
- [26] Celik, I. (2023). Towards Intelligent-TPACK: An empirical study on teachers' professional knowledge to ethically integrate artificial intelligence (AI)-based tools into education. *Computers in Human Behavior* 138, 107468. <http://doi.org/10.1016/j.chb.2022.107468>
- [27] Kim, S., Jang, Y., Choi, S., Kim, W., Jung, H., Kim, S., & Kim, H. (2021). Analyzing teacher competency with TPACK for K-12 AI education. *Künstliche Intelligenz*, 35(2), 139-151. <https://doi.org/10.1007/s13218-021-00731-9>
- [28] Vitanova, A., Atanasova-Pachemska, T., Iliev, D., & Pachemski, G. (2015). Factors affecting the development of ICT competencies of teachers in primary schools. *Procedia-Social and Behavioral Sciences*, 191, 1087-1094. <https://doi.org/10.1016/j.sbspro.2015.04.344>
- [29] Koh, J. H. L., & Chai, C. S. (2014). Teacher clusters and their perceptions of technological pedagogical content knowledge (TPACK) development through ICT lesson design. *Computers & Education*, 70, 222-232. <https://doi.org/10.1016/j.compedu.2013.08.017>
- [30] Lee, M.-H., & Tsai, C.-C. (2010). Exploring teachers' perceived self-efficacy and technological pedagogical content knowledge with respect to educational use of the World Wide Web. *Instructional Science*, 38(1), 1-21. <https://doi.org/10.1007/s11251-008-9075-4>
- [31] Yaghi, H. (2001). Subject matter as a factor in educational computing by teachers in international settings. *Journal of Educational Computing Research*, 24(2), 139-154. <https://doi.org/10.2190/9YWV-DDUL-7G4F-6QVX>

- [32] Li, Z., Wang, C., & Bonk, C. J. (2025). Generative AI for teachers' self-directed professional development: A mixed-methods study. *TechTrends. Advance online publication*. <https://doi.org/10.1007/s11528-025-01123-8>
- [33] Kong, S. C., Lai, M., Li, Y., Chan, T.-Y. D., & Zhang, Y. T. (2025). A latent profile analysis of teachers' knowledge about and perceived usefulness of computational thinking and how teacher profiles relate to student achievement. *Computers & Education*, 232, 105281. <https://doi.org/10.1016/j.compedu.2025.105281>
- [34] Wijaya, T. T., Yu, Q., Cao, Y., He, Y., & Leung, F. (2024). Latent profile analysis of AI literacy and trust in mathematics teachers and their relations with AI dependency and 21st-century skills. *Behavioral Sciences*, 14(11), 1008. <https://doi.org/10.3390/bs14111008>
- [35] Schmid, M., Brianza, E., & Petko, D. (2020). Developing a short assessment instrument for Technological Pedagogical Content Knowledge (TPACK.xs) and comparing the factor structure of an integrative and a transformative model. *Computers & Education*, 157, 103967. <https://doi.org/10.1016/j.compedu.2020.103967>
- [36] Kline, R. B. (2011). *Principles and practice of structural equation modeling(3rd ed.)*. Guilford Press.
- [37] Yi, S., & Lee, Y. (2019). The Analysis of Difference in Software Education Teaching Efficacy according to Variables of In-service Elementary School Teachers. *The Journal of Korean Teacher Education*, 22(4), 1-10. <https://doi.org/10.32431/kace.2019.22.4.001>



#### 이소율

- 2007년 춘천교육대학교 초등교육(교육학사)
- 2017년 한국교원대학교 대학원 초등컴퓨터교육(교육학석사)
- 2020년 한국교원대학교 대학원 초등컴퓨터교육(교육학박사)
- 2010년~2020년 강원도교육청 교사
- 2020년~2022년 한국교원대학교 컴퓨터교육과 Post-Doc.
- 2022년~2023년 순천향대학교 교육대학원 조교수
- 2020년~현재 한국컴퓨터교육학회 편집위원
- 2023년~현재 강원대학교 교육대학원 조교수
- 2025년~현재 강원대학교 RISE사업단 평생교육 연구센터장

✚ 관심분야 : 정보 · SW · AI · 디지털 교육, 융합교육, 교사교육

✉ E-Mail: soyulyi@kangwon.ac.kr



#### 김귀훈

- 1998년 KAIST 전기및전자공학과 (공학사)
- 2000년 KAIST 전자전산학과(공학석사)
- 2019년 KAIST 전기및전자공학부(Ph.D.)
- 2000년~2005년 LG 데이터컴 주임연구원
- 2005년~2020년 ETRI 실장, 책임연구원
- 2020년~현재 한국교원대학교 인공지능융합교육 전공 교수
- 2006년~현재 ITU-T SG11 Rapporteur, Editor
- 2022년~현재 한국AI융합교육연구소 소장
- 2024년~현재 교육정보원 원장

✚ 관심분야 : 인공지능융합교육, AI디지털교과서, 지능형 에지컴퓨팅, 강화학습

✉ E-Mail: kimkh@knue.ac.kr