

생성형 AI는 신입 프로그래머의 성장을 돕는가, 방해하는가?: 인지적 오프로딩과 비판적 사고를 중심으로

(Does Generative AI Help or Hinder the Growth of Novice Programmers?: Focusing on Cognitive Offloading and Critical Thinking)

전광섭*, 이한솔**, 강주영***
(Kwang Sep Jean, Han Sol Lee, Ju Young Kang)

요약

본 연구는 생성형 AI 도구의 확산이 신입(경력4년 미만) 프로그래머의 직무 수행 과정과 성장에 미치는 영향을 실증적으로 규명하는 데 목적이 있다. 특히 인지 부하 이론과 메타인지 이론을 기반으로, AI 도구 사용이 '인지적 오프로딩'을 통해 비판적 사고와 직무만족에 미치는 경로를 분석하고, 개인의 'AI 리터러시'가 이러한 관계를 어떻게 조절하는지 검증하고자 하였다. 이를 위해 현직 신입 소프트웨어 개발자 96명을 대상으로 설문 조사를 실시하였으며, PLS-SEM을 활용하여 분석하였다. 분석 결과, 신입 프로그래머의 AI 도구 사용은 인지적 오프로딩을 유의하게 증가시켰으나, 이것이 직무만족의 저하로 직결되지는 않았다. 특히 AI 리터러시가 높은 집단에서는 인지적 오프로딩이 비판적 사고를 촉진하는 긍정적 조절 효과가 확인되었다. 이는 AI 시대 신입 개발자의 성장을 위해 도구 사용 제한보다는 AI 리터러시 함양을 통한 '똑똑한 위임' 전략이 필요함을 시사한다.

■ 중심어 : 생성형AI ; 신입 프로그래머 ; 인지적 오프로딩 ; 비판적 사고 ; AI 리터러시

Abstract

The purpose of this study is to empirically investigate the impact of the proliferation of generative AI tools on the job performance and growth of novice programmers (with less than 4 years of experience). Based on Cognitive Load Theory and Metacognitive Theory, this study analyzes the path through which AI tool usage affects critical thinking and job satisfaction via 'Cognitive Offloading' and verifies the moderating effect of individual 'AI Literacy'. A survey was conducted on 96 incumbent novice software developers, and the collected data were analyzed using PLS-SEM with SmartPLS. The key findings are as follows: First, the use of generative AI tools by novice programmers significantly increased cognitive offloading. Second, contrary to concerns, the direct negative impact of AI tool usage or cognitive offloading on job satisfaction was not statistically significant. Third, the moderating effect of AI literacy was confirmed. In the group with high AI literacy, the positive relationship between cognitive offloading and critical thinking was strengthened. The results suggest that for the growth of novice developers in the AI era, a strategy of 'smart delegation' through cultivating AI literacy is required, rather than restricting tool usage.

■ keywords : Generative AI ; Cognitive Offloading ; Critical Thinking ; AI Literacy

I. 서론

1. 연구의 배경

최근 CHAT GPT[1], GitHub Copilot[2]과 같은 생성형 AI 도구의 급속한 확산은 소프트웨어 개발 생태계, 그중에서도 특히 업무 경험이 부족

* 준회원, 아주대학교 경영대학 글로벌융합경영학과

** 정회원, 아주대학교 경영대학 글로벌경영학과

*** 정회원, 아주대학교 경영대학 경영인텔리전스학과

이 논문은 2025년 정부(산업통상자원부)의 재원으로 한국산업기술진흥원의 지원을 받아 수행된 연구임(P0020632, 2022년 산업혁신인재성장지원사업)

접수일자 : 2026년 01월 04일

수정일자 : 2026년 02월 22일

게재확정일 : 2026년 03월 09일

교신저자 : 강주영 e-mail : jykang@ajou.ac.kr

한 신입 프로그래머(Novice Programmers)의 업무처리 방식에 근본적인 변화를 가져왔다. 과거 신입 개발자들이 선행의 조언이나 온라인 커뮤니티 검색에 의존하여 지식을 습득했다면, 현재는 대규모 언어 모델(LLM)을 활용해 즉각적으로 코드를 생성하고 오류를 수정하는 방식이 새로운 업무 표준으로 자리 잡고 있다[3].

이러한 변화는 반복적인 코딩 업무를 자동화하고 진입 장벽을 낮추어, 신입 개발자의 업무 효율성을 높이는 긍정적인 기제로 작용하고 있다[5]. 기술적 편리함의 이면에는 인지적 오프로딩이라는 잠재적 위험이 존재한다. 인지 부하 이론(Cognitive Load Theory)에 따르면, 인간의 작업 기억 용량은 제한적이며, 이를 효율적으로 관리하기 위해 학습자는 인지적 노력을 외부 도구나 환경에 위임하려는 경향을 보인다[6, 7]. 인지적 오프로딩은 단기적으로는 작업 기억의 부하를 줄여 과제 수행 속도를 높여주지만, 문제 해결의 전 과정을 AI에 과도하게 의존할 경우 사용자의 내부적인 인지 처리 과정을 축소할 위험이 있다[8, 9].

특히 직무 역량이 형성되는 시기인 신입 프로그래머가 AI 도구에 무비판적으로 의존할 경우, 스스로 코드의 논리 구조를 설계하고 검증하는 비판적 사고의 기회가 구조적으로 감소할 수 있다[8, 10]. 선행 연구들은 AI에 대한 과도한 의존이 사용자의 문제 해결 능력을 저하시키고, 장기적으로는 자신의 직무 수행에 대한 통제감과 효능감을 약화시켜 직무만족에 부정적인 영향을 미칠 수 있음을 경고하고 있다[11, 12]. 즉, AI 도구 사용이 단기적인 성과는 높일 수 있으나, 장기적인 관점에서는 개발자의 전문성 성장과 직무 태도에 위협이 될 수 있다는 우려가 제기된다[9, 13].

2. 연구의 필요성 및 차별성

최근 ChatGPT[1], GitHub Copilot[2]과 같은 생성형 AI 도구의 등장은 소프트웨어 개발 환경

에 혁신적인 변화를 가져왔다. 이러한 도구들은 코드 생성, 디버깅, 문서화 작업을 자동화하여 개발자의 생산성을 높이고, 특히 초보자에게 즉각적인 피드백을 제공함으로써 코딩 효능감을 높이는 긍정적인 도구로 인식되고 있다[5]. 그러나 이러한 기술적 편리함이 인간의 인지적 처리 과정을 대체함에 따라, 학습자가 자신의 인지적 노력을 외부 도구에 위임하는 '인지적 오프로딩(Cognitive Offloading)' 현상이 심화되고 있다는 우려가 제기된다[7].

선행 연구들에 따르면, 디지털 도구에 대한 과도한 의존은 정보를 내재화하지 않고 외부 저장소에 의존하는 '구글 효과(Google Effect)'를 초래할 뿐만 아니라[15], 비판적 검증 과정을 생략하게 만들어 사용자의 비판적 사고 역량을 저하시킬 위험이 있다[8][10]. 특히 직무 역량이 형성되는 결정적 시기에 있는 경력 4년 미만의 신입 프로그래머[43]에게 있어, AI 도구에 대한 무비판적 수용은 문제 해결 능력의 발달을 저해하고 장기적으로는 'AI 의존성(AI Dependence)'을 고착화하여 직무 효능감과 만족도를 떨어뜨릴 수 있다[11][12].

기존 연구들은 주로 생성형 AI의 도입이 업무 성과나 사용 의도에 미치는 영향에 집중해 왔으나[4][6], 이것이 개발자의 인지적 과정과 심리적 태도에 미치는 구조적 관계를 규명한 연구는 부족한 실정이다. 또한, 최근 AI 리터러시가 중요한 역량으로 논의되고 있으나[17][18], 이를 단순한 활용 기술을 넘어 인지적 부작용을 완화하고 성장을 돕는 조절 기제로서 실증한 연구는 미흡하다. 따라서 본 연구는 생성형 AI 도구 사용이 신입 프로그래머의 인지적 오프로딩과 비판적 사고, 직무만족에 미치는 영향을 분석하고, AI 리터러시의 조절 효과를 규명함으로써 AI 시대의 효과적인 인재 육성 전략을 제시하고자 한다.

3. 연구 질문

본 연구는 생성형 AI 도구 사용이 신입 프로그

래머의 성장에 미치는 이중적인 영향(Dual Impact)을 규명하는 데 목적이 있다. 이를 위해 본 연구는 인지 부하 이론과 메타인지 이론을 통합적 관점에서 적용하여, AI 도구 사용, 인지적 오프로딩, 비판적 사고, 직무만족, 그리고 AI 리터러시 간의 구조적 관계를 단계적으로 탐구하고자 한다. 구체적인 연구의 수행 과정과 연구 질문의 도출 배경은 다음과 같다.

첫째, 생성형 AI 도구 사용과 인지적 오프로딩의 관계 규명이다. 인지 부하 이론에 따르면, 학습자는 과제 해결 과정에서 제한된 작업 기억(Working Memory)의 용량을 효율적으로 관리하기 위해 인지적 처리의 일부를 외부 환경이나 도구에 위임하는 전략을 취한다[7, 14]. 선행 연구들은 디지털 도구의 검색 편의성이 높아질수록 사용자가 정보를 내재화하기보다 외부 저장소에 의존하는 '구글 효과(Google Effect)'가 강화됨을 보고하였다[15]. 특히 신입 프로그래머의 경우, 복잡한 코딩 과제에 직면했을 때 생성형 AI가 제공하는 즉각적인 솔루션에 의존함으로써 자신의 인지적 부하를 줄이려는 경향이 두드러질 수 있다[5]. 본 연구는 이러한 이론적 논의를 바탕으로, 실제 현업에 종사하는 신입 프로그래머에게서도 AI 도구 사용이 인지적 노력의 외부 위임, 즉 인지적 오프로딩을 심화시키는지 확인하고자 한다.

연구 질문 1: 신입 프로그래머의 생성형 AI 도구 사용은 인지적 오프로딩을 유의하게 증가시키는가?

둘째, 인지적 오프로딩이 초래하는 인지적 외주화의 결과 분석이다. AI 도구를 통한 인지적 오프로딩이 업무 효율성을 높일 수는 있으나, 그 과정에서 발생할 수 있는 부작용에 대한 우려 또한 제기되고 있다. 최근 연구들은 문제 해결 과정의 지나친 외부 위임이 정보의 비판적 평가와 논리적 검증 과정을 생략하게 만들어, 결과적으로 사용자의 비판적 사고 역량을 약화시킬 수 있다고 지적한다[8, 10]. 또한, 자신의 능력으로 문

제를 해결했다는 성취감과 통제감의 결여는 장기적으로 직무에 대한 흥미와 효능감을 떨어뜨려 직무만족에 부정적인 영향을 미칠 가능성이 있다[1, 12]. 이에 본 연구는 인지적 오프로딩이 단순히 인지 자원을 아끼는 것을 넘어, 개발자의 핵심 역량인 비판적 사고와 직무 태도에 어떠한 인과적 영향을 미치는지 규명하고자 한다.

연구 질문 2: AI 도구 사용으로 인한 인지적 오프로딩은 비판적 사고와 직무만족에 어떠한 영향을 미치는가?

셋째, AI 리터러시의 조절 효과 검증이다. 동일하게 AI 도구를 사용하더라도, 모든 개인이 인지적 오프로딩의 부정적 영향을 겪는 것은 아니다. 메타인지 이론은 개인이 자신의 인지 과정을 점검하고 조절하는 능력에 따라 도구 활용의 결과가 달라질 수 있음을 시사한다[16]. 이와 관련하여 최근 주목받는 개념인 AI 리터러시는 AI 기술의 한계를 이해하고 산출물을 비판적으로 평가하며 주체적으로 활용하는 역량을 의미한다[17, 18]. 선행 연구에 따르면 높은 AI 리터러시를 갖춘 사용자는 AI를 단순한 대체재가 아닌 사고의 확장 도구로 활용하는 경향이 있다[19].

따라서 본 연구는 AI 리터러시가 인지적 오프로딩이 비판적 사고 저하 및 직무만족 하락으로 이어지는 부정적 고리를 끊거나, 오히려 긍정적 기제로 전환시키는 조절 변수로서 기능하는지 검증하고자 한다.

연구 질문 3: AI 리터러시는 AI 도구 사용으로 인한 인지적 오프로딩이 비판적 사고 및 직무만족에 미치는 영향을 조절하는가?

II. 이론적 배경

1. 인지 부하 이론과 인지적 오프로딩

인지 부하 이론(Cognitive Load Theory)은 인간의 인지 구조가 처리할 수 있는 정보량에 한계가 있음을 전제하며, 학습과 문제 해결 과정에서 작업 기억(Working Memory)의 효율적 관리를

강조한다. 이 이론에서는 인지 부하를 과제 자체의 난이도에 의한 '내재적 부하', 정보 제시 방식에 의한 '외재적 부하', 그리고 학습과 이해에 영향을 주는 '본유적 부하'로 구분한다[20, 21]. 최근 디지털 학습 환경의 복잡성이 증가함에 따라, 이러한 인지 부하를 적절히 관리하는 것이 디지털 도구 활용의 핵심 과제로 논의되고 있다[22, 23].

이러한 맥락에서 인지적 오프로딩은 과제 수행 시 요구되는 인지적 처리 용량을 줄이기 위해 기억이나 연산과 같은 인지 과정을 외부 도구에 위임하는 현상으로 정의된다[7]. 이는 자신의 인지 능력을 넘어서는 과제를 해결하기 위한 적응적 전략으로 볼 수 있으나, 한편으로는 인터넷 검색 등에 대한 과도한 의존이 정보의 내재화를 방해하는 '구글 효과(Google Effect)'를 초래한다는 지적도 제기된다[15]. 특히 생성형 AI와 같은 고도화된 도구가 문제 해결 과정 자체를 대체할 경우, 사용자의 인지적 노력이 과도하게 축소되는 '역기능적 오프로딩'이 발생할 수 있다[8, 10]. 실증 연구에 따르면, 이러한 오프로딩은 단기적 성과는 높일 수 있으나 장기 기억 형성 및 지식의 축적에는 부정적 영향을 미치는 것으로 나타났다[9].

2. AI 도구 사용과 신입 프로그래머

생성형 AI(Generative AI) 도구의 등장은 소프트웨어 엔지니어링 교육과 실무 현장에 혁신적인 변화를 가져왔다. GitHub Copilot이나 ChatGPT와 같은 도구는 코드 생성, 오류 수정, 문서화 작업을 자동화하여 개발자의 생산성을 높이는 데 기여한다[2, 3, 6].

선행 연구들에 따르면, 이러한 AI 도구는 특히 초보자(Novice)에게 즉각적인 피드백을 제공함으로써 진입 장벽을 낮추고 코딩 효능감을 높이는 긍정적 효과가 있는 것으로 확인되었다[5, 12, 24]. 구체적으로 AI 도구의 활용은 초보 프로그

래머의 코드 작성 속도를 높이고 문법적 오류를 줄이는 데 유의한 도움을 주는 것으로 보고된다[2, 5].

그러나 이러한 도구적 유용성에도 불구하고, 'AI 의존성(AI Dependence)'에 대한 우려 또한 커지고 있다. 학습자가 AI가 생성한 코드를 이해하지 못한 채 복사, 붙여넣기 하는 행위가 반복될 경우, 문제 해결 능력의 발달이 저해될 수 있다[11, 12]. 이는 AI의 도움으로 문제를 해결한 것을 자신의 능력으로 착각하게 만드는 '메타인지 적 착각' 현상으로 설명된다[25]. 또한, 과도한 AI 의존은 학업적 대만이나 부정직한 학습 태도로 이어질 수 있으며, 이는 결과적으로 개인의 실제 역량과 성취도 간의 괴리를 초래한다는 경고가 제기되고 있다[8, 13].

3. 비판적 사고와 직무만족

비판적 사고(Critical Thinking)는 정보의 신뢰성을 평가하고, 논리적 오류를 식별하며, 합리적인 결론을 도출하는 반성적 사고 능력을 의미한다[26, 27]. AI 시대의 비판적 사고는 AI 산출물의 할루시네이션(Hallucination)을 식별하고, 편향성을 검증하며, 최적의 솔루션을 선별하는 능력으로 확장된다. 그러나 생성형 AI의 높은 성능은 사용자로 하여금 비판적 검증 단계를 생략하게 만드는 '자동화 편향(Automation Bias)'을 유발하여, 사고의 깊이를 얕게 만들 위험이 있다[8, 10].

이러한 AI시대의 인지적 변화는 직무만족(Job Satisfaction)과 같은 정의적 태도에도 영향을 미친다. 소프트웨어 전문가의 직무만족은 기술적 성장과 업무 자율성에 크게 의존하며[1, 28], 온보딩 과정에서의 부정적 경험은 신입 개발자의 이직 의도를 높이는 주요 요인으로 작용한다[29]. 최근 연구 결과들은 AI 도입이 업무 효율을 높여 직무만족을 높일 수도 있지만, 반대로 테크노스트레스(Techno stress)를 유발하거나 자신의 역할이 대체될 것이라는 불안감을 조성하여

만족도를 떨어뜨릴 수도 있음을 시사한다[30, 31]. 이는 AI 도구 사용과 직무만족 간의 관계는 인지적 혹은 심리적 매개 요인에 의하여 달라질 수 있음을 의미한다.

4. AI 리터러시의 조절 효과

AI 리터러시(AI Literacy)는 AI 기술의 원리와 한계를 이해하고, 윤리적으로 활용하며, AI와 협업할 수 있는 능력을 포괄하는 개념이다[17, 18]. 이는 기술적 이해, 비판적 평가, 윤리적 활용, 창의적 적용의 4가지 차원으로 정의되며[18, 32], AI와 효과적으로 소통하기 위한 일련의 핵심 역량으로 개념화된다[17].

메타인지 이론에 근거할 때, AI 리터러시는 개인이 자신의 인지 과정을 점검(Monitoring)하고 조절(Control)하는 핵심 기제로 작용한다[33, 34]. 높은 AI 리터러시를 갖춘 학습자는 AI 도구를 '사과의 파트너'로 활용하며, 결과물을 비판적으로 재구성하는 경향을 보인다[24, 35]. 실증 연구에 따르면, 체계적인 AI 교육은 사용자의 태도와 효능감을 긍정적으로 변화시켜, AI 의존의 부작용을 완화할 수 있음을 입증하였다[32, 36]. 따라서 본 연구는 AI 리터러시가 인지적 오프로딩 상황에서도 비판적 사고를 유지하게 돕는 조절 변수로서 기능할 것으로 가정한다.

5. 통제변수의 선정 근거

본 연구는 독립변수인 신입 프로그래머의 생성형 AI 도구 사용 경험이 종속변수인 직무만족도에 미치는 순수한 영향력을 규명하기 위해, 직무만족도에 유의미한 영향을 미칠 수 있는 주요 외생 변수들을 사전에 통제하고자 하였다. 이를 위해 선행 연구 고찰을 바탕으로 개발자의 직무 태도에 영향을 주는 대표적 요인인 '외부 보상', '역량 개발 기회', '사회적 지지'를 본 연구의 통제변수로 설정하였다.

첫째, 조직 구성원이 지각하는 경제적 보상의 수준과 공정성은 직무 태도를 형성하는 가장 일

차적인 요인이다. 선행 연구들에 따르면 조직이 제공하는 적절한 급여 수준과 이에 대한 보상 만족은 구성원의 직무 동기를 유발하고 지속적인 조직 몰입을 가능하게 하는 기초적인 요인으로 밝혀진 바 있다[37, 38].

둘째, 급변하는 기술 환경에 노출된 소프트웨어 개발자의 직무 특성상, 개인의 전문성 성장은 직무만족과 매우 밀접한 관련이 있다. 개발자에게 있어 최신 기술을 습득할 수 있는 지속적인 학습 환경과 조직 차원의 역량 개발 기회 제공은 단순한 복리후생을 넘어 직무만족을 결정짓는 핵심 동인이자 내재적 보상으로 작용한다[39].

셋째, 조직 내 대인관계와 심리적 환경 또한 신입 사원의 조직 적응에 지대한 영향을 미친다. 업무 수행 과정에서 상사와 동료의 제공되는 정서적 지지는 직무로 인한 스트레스를 완화해 주는 완충 작용을 하며, 원활한 조직 적응을 돕는 중요한 심리적·사회적 자원으로 확인된다[40].

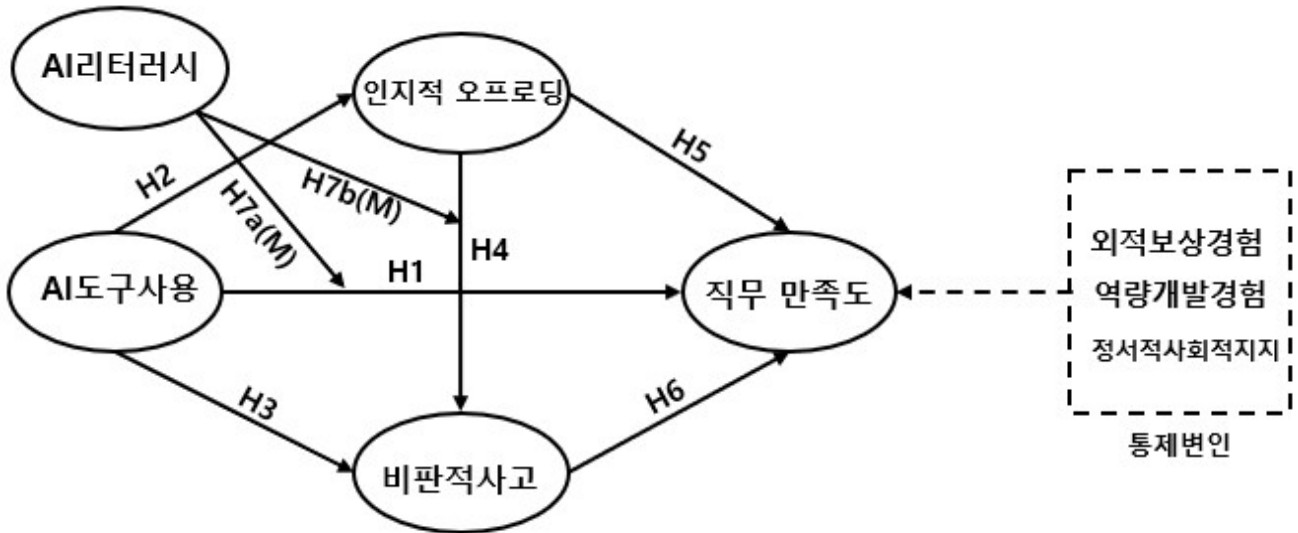
따라서 본 연구는 이들 변수를 통계적으로 통제함으로써, 급여나 동료 관계 등 다른 환경적 요인에 의한 혼입 효과를 배제하고 생성형 AI 도구 사용이 직무만족도에 미치는 고유한 설명력과 영향력을 보다 엄밀하고 정교하게 검증하고자 한다.

III. 연구 모형 및 가설

1. 연구 모형

본 연구는 생성형 AI 도구 사용이 신입 프로그래머의 직무만족에 미치는 구조적 관계를 규명하기 [그림1] 과 같은 연구 모형을 설정하였다.

독립변수는 '생성형 AI 도구 사용', 종속변수는 '직무만족'이며, 이들 관계를 설명하는 매개변수로 '인지적 오프로딩'과 '비판적 사고'를 투입하였다. 또한, 'AI 리터러시'를 조절변수로 설정하여 개인 역량에 따른 차이를 검증하고자 한다. 직무만족에 영향을 미칠 수 있는 '외부 보상', '역량 개발 경험', '사회적 지지'는 통제변수로 설정하였다.



주: 매개효과 가설 H8(ATU→CO→JS), H9(ATU→CT→JS), H10(ATU→CO→CT→JS)

그림1. 연구 모형

2. 연구 가설

가. 주요 변수 간의 직접 효과

생성형 AI 도구는 업무 효율을 높여주지만, 신입 개발자에게는 자신의 역할이 대체될 수 있다는 테크노스트레스(Techno stress)를 유발할 수 있다. 선행 연구에 따르면, 과도한 기술 의존은 자신의 직무 통제감을 약화시켜 결과적으로 직무만족을 저하시키는 요인으로 작용한다[30, 31].

H1: 생성형 AI 도구 사용은 직무만족에 부(-)의 영향을 미칠 것이다.

인지 부하 이론에 의하면, 인간은 복잡한 과제 수행 시 인지적 노력을 최소화하기 위해 외부 도구를 활용하는 전략을 취한다[6, 20, 41]. 생성형 AI의 즉각적인 코드 생성 기능은 신입 개발자로 하여금 문제 해결의 인지 과정을 도구에 위임하게 만들어 인지적 오프로딩을 유의하게 증가시킬 것이다[7, 22].

H2: 생성형 AI 도구 사용은 인지적 오프로딩

에 정(+)의 영향을 미칠 것이다.

생성형 AI 도구에 대한 과도한 의존은 학습자가 스스로 코드를 분석하고 원리를 파악하는 능동적 탐구 과정을 생략하게 만드는 결과를 초래한다. 특히 실증 연구들에 따르면, AI 대화 시스템에 대한 과의존은 복잡한 문제를 해결하는 데 필요한 고차원적 사고 능력의 발달을 저해하며, 이는 실무 환경에 있는 신입 개발자의 비판적 사고 역량을 감소시키는 주요 원인이 된다[11, 12].

H3: 생성형 AI 도구 사용은 비판적 사고에 부(-)의 영향을 미칠 것이다.

문제 해결 과정을 외부에 위임하는 인지적 오프로딩이 심화될수록, 정보의 정확성을 검증하고 논리적으로 재구성하는 비판적 사고의 기회는 박탈된다. 이를 '자동화 편향'으로 설명하며, 오프로딩이 사용자의 비판적 검증 역량을 약화한다고 지적하였다[9][21].

H4: 인지적 오프로딩은 비판적 사고에 부(-)의 영향을 미칠 것이다.

자신의 인지적 노력 없이 AI 도구를 통해 결과를 얻는 과정이 반복될 경우, 개발자는 자신의 성장에 대한 회의감과 업무에 대한 통제 상실을 경험하게 된다. 이는 장기적으로 직무에 대한 흥미와 만족도를 떨어뜨리는 부정적인 결과를 초래할 것이다[1, 8, 42].

H5: 인지적 오프로딩은 직무만족에 부(-)의 영향을 미칠 것이다.

소프트웨어 개발 직무에서 스스로 코드를 설계하고 오류를 해결하는 주체적인 사고 과정은 직무 효능감과 성취감의 원천이다. 비판적 사고를 통해 문제를 해결한 경험은 직무에 대한 내재적 동기를 강화하여 직무만족을 높이는 핵심적 선행 요인이다[1, 27].

H6: 비판적 사고는 직무만족에 정(+)의 영향을 미칠 것이다.

나. 조절 효과(Moderating Effects)

AI 리터러시가 높은 사용자는 AI 도구를 자신의 역량을 확장하는 파트너로 인식하여 효능감을 유지한다[18, 32]. 이는 AI 도구 사용이 직무만족에 미치는 부정적 영향(불안감 등)을 완화하고, 도구 활용을 통한 성취감을 높이는 조절 기제로 작용할 것이다[36].

H7a(M): AI 리터러시는 생성형 AI 도구 사용과 직무만족 간의 관계를 조절할 것이다.

메타인지 이론에 따르면, 높은 AI 리터러시를 갖춘 개인은 인지적 오프로딩 상황에서도 자신의 인지 과정을 모니터링하고 조절할 수 있다[33, 34]. 따라서 AI 리터러시는 오프로딩이 비판적

사고 저하로 이어지는 부정적 영향을 완화하거나, 오히려 AI 산출물을 비판적으로 검토하는 기회로 전환시키는 조절 효과를 가질 것이다[35, 36].

H7b(M): AI 리터러시는 인지적 오프로딩과 비판적 사고 간의 관계를 조절할 것이다.

다. 매개 효과(Mediating Effects)

AI 도구 사용은 인지적 오프로딩을 증가시키고(H2), 증가한 오프로딩은 직무만족을 저하시키는(H5) 매개 경로가 존재할 것이다.

H8: 인지적 오프로딩은 AI 도구 사용과 직무만족도 사이를 매개할 것이다. (단일 매개)

AI 도구 사용은 비판적 사고를 저해하고(H3), 비판적 사고의 저하는 직무만족 감소로 이어지는(H6) 매개 경로가 존재할 것이다.

H9: 비판적 사고는 AI 도구 사용과 직무만족도 사이를 매개할 것이다. (단일 매개)

본 연구는 "AI 도구 사용이 인지적 오프로딩을 증가시켜 비판적 사고가 저하되며 직무만족 감소"로 이어지는 연쇄적인 인과 경로를 가정한다. 이는 인지 부하 이론과 메타인지 이론을 통합적으로 설명하는 핵심 경로가 될 것이다.

H10: 인지적 오프로딩과 비판적 사고는 AI 도구 사용과 직무만족도 사이를 순차 매개할 것이다. (이중 매개)

IV. 연구 방법

1. 연구 대상 및 자료수집

본 연구는 생성형 AI 도구를 현업에서 활용하고 있는 경력 4년 미만의 신입 프로그래머를 연구 대상으로 설정하였다. 신입 프로그래머의 기

준을 경력 4년 미만으로 한정된 것은 기술 습득 단계 모델과 국내 소프트웨어 산업 기준에 근거한다. 기술 습득 과정에 관한 선행 이론에 따르면, 입문 후 약3-4년까지의 시기는 규칙에 의존하는 '초보(Novice)' 단계에서 맥락을 파악하기 시작하는 '상급 초보' 단계로 넘어가는 이행기로 정의된다[43]. 또한, 이는 한국소프트웨어산업협회(KOSA)의 기술자 등급 기준에서 과거 '초급 기술자'로 분류되던 기간과 부합하며[44, 45], 실무 역량이 본격적으로 형성되는 산업기술인력 경력 경로의 초기 단계와도 일치한다[46].

자료수집은 2025년 8월 10일부터 11월19일까지 약3.5개월간 온라인 설문조사(Google Forms)를 통해 진행되었다. 본 연구의 모집단인 '현직 신입 개발자'는 기업 보안 정책과 과중한 업무 특성상 외부 연구자의 접근이 매우 제한적이다. 이에 본 연구는 개발자 전문 커뮤니티와 현직자 네트워크를 활용하여 데이터 확보에 주력하였으며, 단순한 학생 표본이 아닌 실제 업무 환경에 노출된 현직자를 선별하기 위해 '현직 여부'와 '경력4년 미만 여부'를 묻는 이중 스크리닝 질문을 배치하여 연구 대상의 적합성을 엄격히 통제하였다.

그 결과 총150부의 설문이 회수되었으나, 스크리닝 기준을 통과하지 못한 51부(경력 초과 또는 비 현직자)와 불성실한 응답3부를 제외하고, 최종적으로96부(유효율64.0%)의 데이터를 분석에 활용하였다. 이는PLS-SEM 분석을 위한 최소 표본 수 요건(G*Power 기준)을 충족하며[51], 접근이 어려운 특수 직군을 대상으로 확보된 진성 현직자 데이터라는 점에서 높은 연구적 가치를 지닌다.

2. 변수의 조작적 정의

본 연구의 모든 변수는 선행 연구를 바탕으로 본 연구의 맥락인 '신입 프로그래머의 AI 활용 환경'에 부합하도록 조작적으로 정의하였다.

표1. 변수의 조작적 정의

코드	측정 문항	인용
ATU	“나는 의사결정을 내릴 때AI 도구에 의존한다.” “나는AI 도구가 제공하는 추천을 신뢰한다.”등5개 항목	[8]
CO	“나는 구글등 검색엔진을 통해 정보를 빠르게 찾기 위해 자주 사용한다.” “나는 스스로 생각하기 보다 온라인으로 답을 검색할 때가 많다.” 등5개 항목	[7] [8]
CT	“나는 정보 출처를 비판적으로 평가하는 빈도가 높다고 생각한다.” “나는AI가 제공하는 정보전체나 근거를 의심해 본다.”등5개 항목	[10]
JS	“나는 내가 맡은일에 대한 공정한 보상을 받고 있다고 느낀다.” “나는 내가 맡은 일이 중요하고 의미 있다고 생각한다.” 등5개 항목	[1, 29]
AL	“나는 일상 업무를 돕기 위해AI제품을 능숙하게 사용할 수 있다.” “나는 새로운AI 어플이나 제품을 사용할 때 항상 윤리적 원칙을 준수한다.”등8개 항목	[18]
CEC	“나는 현재 급여 수준에 만족한다.” “나는 성과에 따라 공정하게 보상을 받고 있다고 느낀다.”등5개 항목	[37]
EDE	“우리회사는 구성원의 경력 개발을 적극적으로 지원한다.” “나는 내가 받는 교육 이 개발에 만족한다.”등5개 항목	[39]
ESS	“우리 팀은 내 의견에 관심을 기울이는 편이다” “우리 팀은 내 목표와 가치를 존중해 주는 편이다.”	[40]

주)ATU(AI 도구사용), CO(인지적 오프로딩), CT(비판적사고), JS(직무만족도), AL(AI리터러시), CEC(외부보상), EDE(경력개발경험), ESS(정서적 사회적지지)

3. 분석 방법

수집된 데이터의 통계 처리를 위해SmartPLS 4.0 소프트웨어를 활용하여 최소자승 구조방정식(PLS-SEM) 분석을 실시하였다. PLS-SEM은 정규성 가정에 덜 민감하고, 본 연구와 같이 표본수가 상대적으로 적거나(N<100) 이론 개발 단계의 탐색적 연구에 적합한 분석 방법이다[47]. 분석 절차는1단계 측정 모형의 신뢰도(Cronbach's α, CR)와 타당도(AVE, 판별 타당도) 검증, 2단계 부트스트래핑(Bootstrapping)기법(5,000회 재추출)을 이용한 구조 모형 및 가설 검증 순으로 진행되었다.

V. 연구 결과

1. 분석 방법 및 절차

본 연구는 연구 모형의 타당성을 검증하고 가설을 검증하기 위해 SmartPLS 4.0을 이용한 최소자승 구조방정식(PLS-SEM) 분석을 실시하였다. PLS-SEM은 데이터의 정규성 가정에 상대적으로 덜 민감하며, 이론 개발 단계의 탐색적 연구에서 모형의 설명력을 극대화하는 데 적합하다[47]. 분석 절차에 따라 1단계에서 측정모형의 집중 타당도를 평가하였으며[48], 잠재 변수 간의 다중공선성 및 공통방법 편향(CMV) 문제를 점검하였다[49]. 마지막으로 HTMT 기준을 적용하여 판별 타당도를 엄밀하게 검증하였다[50].

표2. 신뢰도 및 수렴타당도 분석 결과

구성개념	측정 문항	표준 요인적재치	Cronbach's α	개념신뢰도 (CR)	평균분산추출값 (AVE)
AI 리터러시	AL1	0.780	0.899	0.923	0.667
	AL2	0.873			
	AL3	0.870			
	AL4	0.728			
	AL5	0.759			
	AL6	0.876			
AI 도구사용	ATU1	0.862	0.845	0.895	0.683
	ATU2	0.875			
	ATU3	0.686			
	ATU4	0.866			
인지적오프로딩	CO3	0.718	0.698	0.834	0.627
	CO4	0.858			
	CO5	0.792			
비판적사고	CT1	0.754	0.827	0.877	0.589
	CT2	0.659			
	CT3	0.789			
	CT4	0.793			
	CT5	0.833			
직무만족도	JS1	0.570	0.812	0.869	0.575
	JS2	0.792			
	JS3	0.743			
	JS4	0.803			
	JS5	0.852			
외부보상경험	ECE1	0.866	0.908	0.932	0.737
	ECE2	0.917			
	ECE3	0.926			
	ECE4	0.666			
	ECE5	0.890			
역량개발경험	CDE1	0.866	0.916	0.937	0.749
	CDE2	0.891			
	CDE3	0.881			
	CDE4	0.885			
	CDE5	0.799			
정서적지지	ESS1	0.892	0.927	0.943	0.769
	ESS2	0.917			
	ESS3	0.829			
	ESS4	0.862			
	ESS5	0.883			

2. 측정모형의 신뢰도 및 타당도 검증

측정모형의 평가를 위해 내적 일관성 신뢰도

(Internal Consistency Reliability)와 수렴타당도 (Convergent Validity)를 검증하였다. 선행 연구에서 제시한 기준에 따라 요인적재량(Outer Loading) 0.7 이상, 복합신뢰도(CR) 0.7 이상, 평균분산추출(AVE) 0.5 이상을 충족하는지 확인하였다[47, 48]. 분석 과정에서 기준치에 미달하거나 타당도를 저해하는 문항(CO1, CO2, ATU5 등)은 제거하여 모형의 적합도를 높였다.

분석 결과는<표2>와 같다. 모든 측정 문항의 표준 요인적재량은0.570에서0.926 사이로 나타나 수용 기준을 충족하였다. 특히 신뢰도 지표인 복합신뢰도(CR) 값은0.834에서 0.943의 분포를 보여, 기준치 인 0.7을 상회하는 높은 내적 일관성을 확보하였다. 또한, AVE 값은0.575에서 0.769로 나타나 모든 잠재 변수가 기준치 인 0.5를 초과하여 수렴타당성이 입증되었다[48, 50].

표3. 판별 타당도 검증 결과

변수	ATU	AL	CT	EDE	ECE	CO	ESS	JS
AI 도구사용	0.826							
AI 리터러시	0.537	0.817						
비판적사고	0.203	0.503	0.768					
역량개발경험	0.001	0.123	0.117	0.865				
외부보상경험	0.200	0.109	0.118	0.680	0.858			
인지적오프로딩	0.596	0.478	0.294	-0.128	0.060	0.792		
정서적지지	0.139	-0.015	-0.083	0.577	0.467	-0.061	0.877	
직무만족도	0.280	0.279	0.218	0.628	0.650	0.211	0.513	0.758

주) 대각선 값은 변수의 AVE의 제곱근을 의미하고, 대각선 아래 값은 변수 간 상관계수를 나타냄

표4. 내부 VIF 값(Inner VIF)

변수	ALT	AL	CT	EDE	ECE	CO	ESS	JS	AL x ATU	AL x CO
AI 도구사용			1.778			1.000		2.077		
AI 리터러시			1.491					2.116		
비판적사고								1.441		
역량개발경험								2.660		
외부보상경험								2.082		
인지적오프로딩			1.766					1.762		
정서적지지								1.676		
직무만족도										
AI 리터러시 x AI 도구사용								1.240		
AI 리터러시 x 인지적오프로딩			1.108							

표5. HTMT

변수	ALT	AL	CT	EDE	ECE	CO	ESS	JS	AL x TAU	AL x CO
AI 도구사용										
AI 리터러시	0.588									
비판적사고	0.218	0.556								
역량개발경험	0.133	0.147	0.163							
외부보상경험	0.223	0.135	0.156	0.731						
인지적오프로딩	0.764	0.606	0.364	0.181	0.112					
정서적지지	0.156	0.167	0.134	0.605	0.510	0.103				
직무만족도	0.330	0.343	0.297	0.697	0.706	0.295	0.545			
AI 리터러시 x AI 도구사용	0.301	0.377	0.141	0.200	0.151	0.181	0.145	0.158		
AI 리터러시 x 인지적오프로딩	0.172	0.141	0.103	0.078	0.190	0.363	0.136	0.072	0.542	

3. 판별 타당도 및 구조 모형의 적합도검증

측정 변수 간의 차별성을 확인하기 위해

Fornell-Larcker 기준과 HTMT 기준을 적용하였다. <표3> 의Fornell-Larcker 기준 분석 결과, 각 잠재 변수의 AVE 제곱근 값(대각선)은0.758에서0.877로 나타나, 타 변수 간의 상관계수보다 모두 높게 측정되어 판별 타당성이 확보되었다[48]. 또한, 최근PLS-SEM 연구에서 보다 엄격한 기준으로 권장되는 HTMT 분석 결과<표5>에서도 모든 변수 간의 비율이 임계치인0.85 또는0.90을 밑도는 것으로 나타나(최대값0.764), 판별타당성이 확고히 입증되었다[50].

구조모형의 평가에 앞서 변수 간의 다중공선성(Multicollinearity)을 확인하기 위해 내부VIF(Inner VIF) 값을 검토하였다. 선행 연구에서 제시한 지침에 따르면VIF 값이3.0(보수적 기준) 또는5.0 미만일 때 공선성 문제가 없는 것으로 간주된다[47]. <표4>와 같이 본 연구의 모든 경로 VIF 값은1.000에서2.660 사이로 나타나 기준치를 충족하였으므로, 구조적 관계 검증에 있어 통계적 왜곡의 우려가 없음을 확인하였다. 동시에 본 연구의 구조모델 타당성을 다각도로 검토하기 위해SRMR(Standardized Root Mean Square Residual)과NFI(Normed Fit Index) 지수를 산출하여 모델 적합도를 분석하였다. 분석결과 SRMR은0.098, NFI는0.626으로 확인되었다. 해당 수치는 엄격한 권장 임계치(SRMR < 0.08, NFI > 0.90)에는 다소 미치지 못하는 수준이나, 신입 프로그래머라는 특정 집단을 대상으로 한 소 표본(n=96) 연구이자 탐색적 연구의 성격상 모델의 전반적인 인과관계와 경향성을 파악하기에는 수용 가능한 범위 내에 있는 것으로 판단하였다. 특히PLS-SEM 분석은 정규성 가정에 덜 민감하며 이론 개발 단계의 탐색적 연구에 적합하다는 점을 고려할 때[47], 본 모델은 가설 검증을 위한 통계적 타당성을 확보한 것으로 간주하였다.

4. 응답자의 일반적 특성

본 연구의 실증 분석을 위해 설문에 참여한 응답

자는 총 96명이며, 이들의 구체적인 인구통계학적 특성을 빈도분석을 통해 살펴본 결과는 <표6>과 같다.

표6. 표본의 인구통계학적 특성

변수	구분	빈도 (N=96)	비율 (%)
성별	남성	77	80.2
	여성	19	19.8
연령대	20 세~ 29 세	46	47.9
	30 세~ 39 세	39	40.6
	40 세~ 49 세	7	7.3
	50 이상	4	4.2
학력	고등학교 졸업	4	4.2
	대학교재학(2/4)	4	4.2
	대학교졸업(2/4)	71	74.0
	대학원 석사졸업	12	12.5
근무형태	대학원 박사졸업	5	5.2
	정규직	86	89.6
	계약직	4	4.2
	프리랜서	1	1.0
주요업무 유형	인턴	2	2.1
	기타(학생)	3	3.1
	응용 S/W 개발	31	32.3
	시스템 S/W	28	29.2
근속연수	데이터엔지니어	17	17.7
	백엔드 개발	20	20.8
	0.5 년~ 1 년	29	30.2
	1 년~ 2 년	21	21.8
조직규모	2 년~ 3 년	20	20.8
	3 년~ 4 년	26	27.2
	10 명 미만	12	12.5
	10 명~ 50 명	30	31.2
AI 도구 사용빈도 (주간)	50 명~ 100 명	17	17.7
	100 명~ 200 명	9	9.4
	200 명 이상	28	29.2
	1 회~ 3 회	16	16.7
AI 도구 사용시간 (일일)	4 회~ 6 회	20	20.8
	7 회 이상	60	62.5
	10 분 미만	7	7.3
	10 분~ 30 분	25	26.0
AI 도구 사용시간 (일일)	30 분~ 1 시간	21	21.9
	1 시간~ 2 시간	20	20.8
	2 시간 이상	23	24.0

우선 성별 분포를 살펴보면, 남성이 77명(80.2%), 여성이 19명(19.8%)으로 나타나 남성 응답자의 비율이 전체의 80% 이상을 차지하며 압도적으로 높게 나타났다. 연령대의 경우, 20대가 46명(47.9%)으로 전체의 약 절반에 달해 가장 높은 비중을 보였으며, 30대가 39명(40.6%)으로 그 뒤를 이어 응답자의 대다수가 20~30대 실무자로 구성되어 있음을 확인하였다.

학력 수준은 대학교 졸업자가 71명(74.0%)으로 집계되어 대다수가 4년제 대학 졸업 이상의 학력을 보유한 것으로 파악되었다. 근무 형태에 있어서는 정규직이 86명(89.6%)으로 가장 높은 빈도를 보여, 본 연구의 표본이 비교적 안정적인 고용 환경에 있는 집단을 중심으로 구성되었음을 시사한다. 주요 업무 유형은 응용 S/W 개발이 32.3%(31명)로 가장 많았고, 시스템 S/W 개발이 29.2%(28명)로 나타나 두 분야가 전체 업무 영역의 과반을 차지하였다. 마지막으로 현 직장에서의 근속 연수는 0.5년 이상 1년 미만 구간이 29명(30.2%)으로 가장 높게 조사되어, 본 연구가 의도한 바와 같이 실무 경력이 비교적 짧은 신입급 인력이 주요 분석 대상임이 확인되었다.

표7. 주요 사용 생성형AI 도구

변수	구분	빈도 (N=96)	비율 (%)
주요 사용 생성형 AI 도구 (복수 응답)	ChatGPT	91	94.8
	Gemini	49	51.0
	Claude	32	33.3
	GitHub	31	32.3
	Cursor	25	26.0
	Notion AI	14	14.6
	Bing AI	7	7.3
	뤼튼	2	2.1
	Copilot	1	1.0
	Perplexity	1	1.0

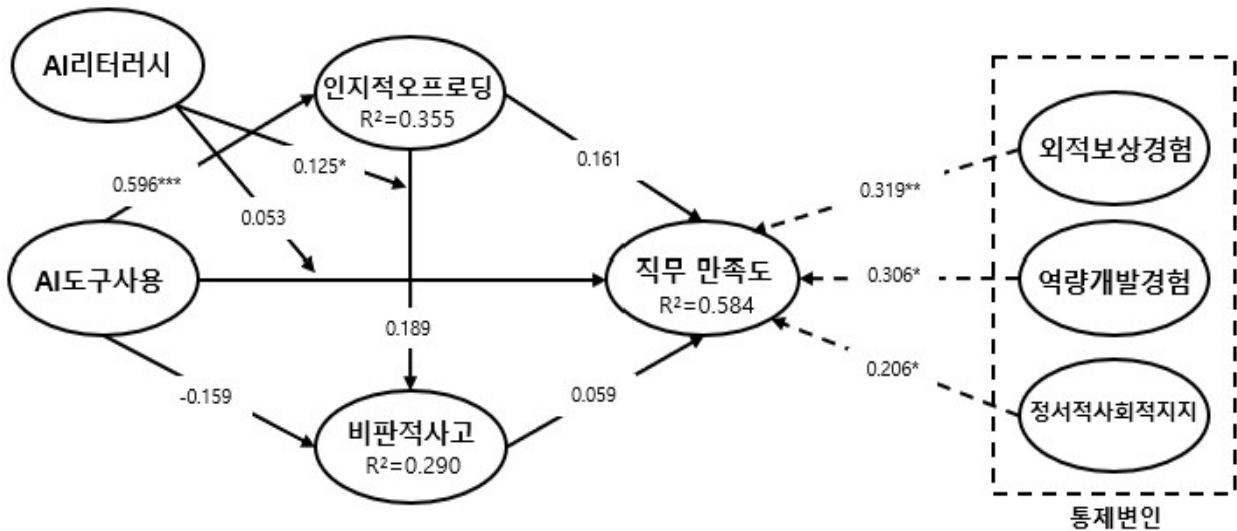


그림 2. 구조 모형 분석 결과

5. AI 활용 현황

응답자들의 생성형AI 도구 활용 현황은(표7)과 같다. 가장 많이 사용하는 도구(복수 응답)는 ChatGPT가 91명(94.8%)으로 압도적으로 높았으며, Gemini(51.0%), Claude(33.3%), GitHub Copilot(32.3%) 순으로 나타났다. 주간 사용 빈도는 7회 이상 사용한다는 응답이 60명(62.5%)으로 과반수를 차지해 업무 활용도가 매우 높음을 확인하였다.

6. 구조 모형 분석 및 가설 검증

구조모형의 적합도와 변수 간의 직접적인 영향 관계(주 효과)를 검증하기 위해 부트스트래핑(Bootstrapping)을 5,000회 실시하였다. 분석 결과는 <표8> 과 같으며, 구조모형의 경로 분석 결과물[그림1]에 도식화하였다. 모형의 설명력(R^2)을 살펴보면, 직무 만족도는 0.584, 인지적 오프로딩은 0.355, 비판적 사고는 0.290으로 나타났다. 구체적인 경로 분석 결과를 살펴보면, 생성형AI 도구 사용(ATU)은 인지적 오프로딩(CO)에 유의한 정(+)의 영향을 미치는 것으로 나타났다($\beta=0.596$, $t=7.907$, $p<0.001$). 반면 생성형AI 도구 사용의 비판적 사고(CT) ($\beta=-0.159$, $t=1.400$, $p=0.162$)와 직무만족도 (JS)($\beta=0.045$, $t=0.466$, $p=0.641$)에 대한 직접 효과는 통계적으로 유의하지 않았다.

한편, 인지적 오프로딩(CO)은 비판적 사고(CT)에 대해 경계적으로 유의한(marginally significant, $p<0.10$) 정(+)의 영향을 보였으나($\beta=0.189$, $t=1.884$, $p=0.060$), 직무만족도(JS)에 대한 직접 효과는 유의하지 않았다($\beta=0.161$, $t=1.599$, $p=0.110$). 비판적 사고(CT)의 직무만족도(JS)에 대한 영향 역시 유의하지 않은 것으로 나타났다($\beta=0.057$, $t=0.701$, $p=0.483$).

반면, 통제변수는 모두 직무만족도에 유의한 정(+)의 영향을 미치는 것으로 나타났다. 구체적으로 역량개발경험(EDE) ($\beta=0.306$, $t=2.411$, $p=0.016$), 외부보상경험(CEC)($\beta=0.319$, $t=2.935$, $p=0.003$), 정서적지지(ESS)($\beta=0.206$, $t=2.297$, $p=0.022$) 순으로 영향력이 확인되었다

다음은 생성형AI 도구 사용과 종속변수 간의 관계에서 인지적 오프로딩과 비판적 사고의 매개 효과를 검증한 결과는 <표9>와 같다. 분석 결과, 생성형AI 도구 사용이 인지적 오프로딩을 거쳐 비판적 사고에 미치는 간접효과는 경계적으로 유의하였다($\beta=0.113$, $t=1.744$, $p=0.081$). 그러

나 생성형AI 도구 사용이 직무만족도에 미치는 간접효과는 모든 경로에서 유의하지 않았다. 구체적으로 인지적 오프로딩 매개($\beta=0.096$, $p=0.144$), 비판적 사고 매개($\beta=-0.009$, $p=0.572$), 그리고 인지적 오프로딩과 비판적 사고의 이중매개($\beta=0.006$, $p=0.582$) 경로 모두 통계적 유의성이 확보되지 않았다. 따라서 본 연구의 매개 경로는 전반적으로 지지되지 않았으며, 생성형AI 도구 사용의 비판적 사고 간접경로만 경계적으로 확인되었다.

표8. 주 효과 분석 결과

경로	원표본 (β)	t 값	p 값
ATU -> CT	-0.159	1.400	0.162
ATU -> CO	0.596	7.907	0.000
ATU -> JS	0.045	0.466	0.641
AL x ATU -> JS	0.053	0.795	0.427
AL x CO -> CT	0.125	1.973	0.049
CT -> JS	0.057	0.701	0.483
EDE -> JS	0.306	2.411	0.016
CEC -> JS	0.319	2.935	0.003
CO -> CT	0.189	1.884	0.060
CO -> JS	0.161	1.599	0.110
ESS -> JS	0.206	2.297	0.022

주: ATU(AI도구사용), CO(인지적 오프로딩), CT(비판적 사고), JS(직무만족도), AL(AI리터러시), CEC(외부보상경험), EDE(경력개발경험), ESS(정서적 사회적 지지)

표9. 매개효과 분석 결과

경로	원표본 (β)	t 값	p 값
ATU->CO->JS	0.096	1.460	0.144
ATU->CT-> JS	-0.009	0.566	0.572
ATU->CO->CT-> JS	0.006	0.550	0.582
AL->CT->JS	0.029	0.665	0.506
CO->CT->JS	0.011	0.569	0.569
ATU->CO->CT	0.113	1.744	0.081

주: ATU(AI 도구사용), CO(인지적 오프로딩), CT(비판적사고), JS(직무만족도), AL(AI 리터러시),

AI 리터러시(AL)의 조절 효과를 검증한 결과는 <표8>와 같다. 상호작용항 분석에서AI 도구 사용(ATU)과 직무 만족도(JS)의 관계에 대한AI 리터러시의 조절효과는 유의하지 않았다($\beta=0.053$, $t=0.795$, $p=0.427$). 반면, 인지적 오프로딩(CO)과 비판적 사고(CT)의 관계에 대한 AI 리터러시의 조절 효과는 유의한 정(+)의 영향을 보

였다($\beta=0.125, t=1.973, p=0.049$).

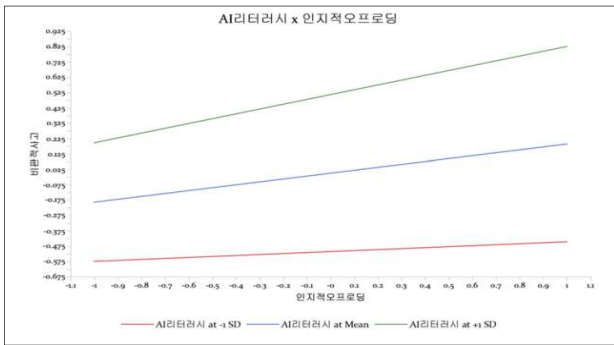


그림3. AL x CO->CT 조절 효과 그래프

확인된 조절 효과의 구체적인 양상을 파악하기 위해, AI 리터러시의 수준을 평균(Mean), 평균 +1 표준편차(+1SD), 평균 -1 표준편차(-1SD)로 구분하여 조건부 직접 효과(Conditional Direct Effect)를 검증하는 단순 기울기(Simple Slope) 분석을 실시하였다[51]. 분석 결과는 <표10>과 같으며, 이를 구체적으로 살펴보면 다음과 같다.

첫째, 가장 주목할 지점은 AI 리터러시가 높은 집단(+1 SD)의 분석 결과이다. 해당 집단에서는 인지적 오프로딩(CO)이 비판적 사고(CT)에 미치는 영향의 경로계수가 0.314($t=2.274, p=0.023$)로 산출되어 통계적으로 유의미한 정(+)의 효과를 나타냈다. 이는 사용자가 높은 수준의 AI 리터러시를 보유하고 있을 때, 도구를 통한 인지적 효율화가 고차원적 사고 역량의 증진으로 전이될 수 있음을 시사한다.

둘째, AI 리터러시 수준이 낮거나(-1 SD) 평균(Mean)인 집단에서는 상반된 양상이 관찰되었다. 리터러시 저집단의 경로계수는 0.064($p=0.503$)에 불과하여 통계적 유의성이 확보되지 않았으며, 평균 집단 역시 0.189($p=0.060$)로 유의수준 0.05 기준을 충족하지 못하였다. 특히 리터러시 수준이 낮아질수록 경로계수가 급격히 감소하고 유의도가 상실되는 결과는, 기초 역량이 결여된 상태에서 오프로딩이 비판적 사고의 향상에 기여하

기 어렵다는 점을 수치적으로 대변한다.

이러한 결과는 <그림3>의 조절 효과 그래프를 통해서도 시각적으로 명확히 확인된다.

AI 리터러시가 높은 집단(녹색 선)은 인지적 오프로딩이 증가함에 따라 비판적 사고가 파르게 상승하는 기울기를 보이는 반면, 낮은 집단(빨간색 선)은 기울기가 매우 완만하여 비판적 사고 수준의 변화가 거의 없음을 알 수 있다.

종합하면, <표10>의 결과는 인지적 오프로딩이 긍정적인 교육적 성과로 이어지기 위해서는 반드시 높은 수준의 AI 리터러시가 선행 조건(Condition)으로 작용해야 함을 실증한다. 이는 "생성형 AI가 신입 프로그래머의 성장을 돕는가?"라는 본 연구의 대주제에 대하여, 단순한 기술 활용 자체보다 사용자의 역량적 개입이 성장의 질을 결정하는 핵심 변수임을 보여주는 결정적 근거가 된다.

표10. 조건부 직접효과 결과

경로	원표본 (β)	t 값	p 값
ATU -> JS, AL at +1 SD	0.098	0.782	0.434
CO -> CT, AL at +1 SD	0.314	2.274	0.023
ATU -> JS, AL at -1 SD	-0.009	0.081	0.936
CO -> CT, AL at -1 SD	0.064	0.670	0.503
ATU -> JS, AL at Mean	0.045	0.466	0.641
CO -> CT, AL at Mean	0.189	1.884	0.060

VI. 결론

1. 연구 결과의 요약 및 논의

본 연구는 생성형 AI가 보편화된 시점에서 실무에 진입한 신입 프로그래머를 대상으로 AI 도구 사용, 인지적 오프로딩, 비판적 사고, 직무만족도 간의 구조적 관계를 규명하고, AI 리터러시의 조절 효과를 실증적으로 검증하였다. 도출된 통계적 결과에 대한 요약과 연구 대상의 인구통계학적 특성 및 한국의 사회적 맥락을 고려한 심

충적인 논의는 다음과 같다.

첫째, AI 도구 사용과 AI 리터러시는 직무만족도에 직접적인 영향을 미치지 않았으며, 두 변수 간의 조절 효과 또한 유의하지 않았다. 이러한 결과는 생성형 AI가 현대 프로그래밍 실무 현장에서 더 이상 특별한 성취를 체감하게 하는 '동기 요인'이 아닌, 업무 수행을 위한 보편적 전제 조건인 위생 요인(Hygiene Factor)이자 필수재로 고착화되었을 개연성을 시사한다. 신입 프로그래머들에게 AI 도구는 이미 필수적인 업무 인프라로 인식되고 있으며, 이러한 기술적 포화 상태에서는 도구의 활용 수준만으로 직무만족의 유의미한 변화를 이끌어내는 데 일정한 한계가 존재하는 것으로 해석해 볼 수 있다.

이와 관련하여 본 연구에서 나타난 다수의 가설 기각은 초기 모델 설정 시의 대전제에 대한 보다 심층적인 검토의 필요성을 제기한다. 비록 가설 검증을 위한 충분한 통계적 유의성을 확보하지 못한 측면이 있으나, 이는 역설적으로 AI 보편화에 따른 기술 수용 환경의 변화를 투영한 결과로 이해될 여지가 있다[47, 51]. 특히 인지적 오프로딩이 비판적 사고에 미치는 영향이 유의하지 않았던 점 역시, 사용자의 역량에 따라 오프로딩의 성격이 가변적일 수 있다는 점을 시사하며[41], 결과적으로 AI가 일상화된 환경에서 개인의 리터러시 역량이 개입될 때 실질적인 성장이 일어날 수 있다는 본 연구의 가정을 부분적으로 뒷받침하는 근거로 조심스럽게 제시될 수 있다[42]. 이러한 결과는 AI 활용을 단순한 성과 향상의 동기 요인으로 접근했던 기존 기술 수용 연구들과 달리, 생성형 AI가 이미 신입 개발자에게 전구나 인터넷과 같은 필수재(Essential Goods)적 성격의 기본 인프라로 고착화되었음을 시사하며 연구의 학술적 차별성을 더한다.

둘째, 인지적 오프로딩과 비판적 사고의 관계에

서 AI 리터러시는 핵심적인 조절 기제로 작용함이 확인되었다. 전체 집단을 대상으로 한 분석에서는 인지적 오프로딩이 비판적 사고에 미치는 영향이 통계적으로 경계적으로 유의한 수준($p=0.060$)에 그쳤다. 그러나 조절 효과를 구체적으로 분석한 결과, AI 리터러시가 높은 집단에서는 인지적 오프로딩이 비판적 사고를 통계적으로 유의하게 향상시키는 것으로 나타났다($\beta=0.314, p<0.05$). 반면, AI 리터러시 수준이 낮은 집단에서는 유의한 영향이 발견되지 않았다.

이러한 결과는 인지적 오프로딩에 대한 기존의 우려, 즉 도구에 대한 의존이 인간의 사고력을 저하시키는 인지적 구두쇠(Cognitive Miser) 현상을 유발할 것이라는 가설을 부분적으로 반박한다. 연구 결과는 사용자의 AI 리터러시 역량이 개입될 때 오프로딩은 단순한 사고의 회피가 아니라 전략적 사고의 확장으로 전환됨을 보여준다. AI 리터러시가 높은 학습자는 단순 코딩이나 문법 교정과 같은 저차원적 인지 과정을 AI에 위임하고, 확보된 인지 자원을 코드의 논리적 검증이나 구조 설계와 같은 고차원적 비판적 사고 활동에 재투자하는 효율적인 인지 전략을 구사하고 있는 것이다. 이는 인지적 오프로딩을 단순한 사고의 퇴화로 보았던 기존의 부정적 견해를 넘어, 리터러시가 뒷받침될 때 기술 의존이 '전략적 자원 재배치(Cognitive Reallocation)'를 통한 지능적 협업의 진화로 이어질 수 있음을 입증하여 이론적으로 기여한다.

셋째, 이러한 긍정적인 조절 효과는 본 연구 대상이 가진 한국적 특수성과 과도기적 세대의 특수성에 기인한 것으로 심도 있게 논의될 수 있다. 본 연구의 설문 응답자는 96명 중 80.2%가 남성이고 90% 이상이 대졸 이상의 학력을 보유하고 있다. 한국 남성의 군 의무 복무 기간과 대학 재학 기간을 고려할 때, 신입 프로그래머들의 평균 입직 연령은 20대 중후반(26~29세)에 형성된다. 중요한 점은 이들이 생성형 AI가 보편화되기 이전인 2022년 이전에 프로그래밍 입문 교육을 받

은 세대라는 사실이다.

본 연구의 결과는 인지적 오프로딩이 비판적 사고에 미치는 영향이 AI 리터러시 수준에 따라 차별적으로 나타날 수 있음을 시사한다. 특히 리터러시 고집단에서 나타난 정(+)의 조절 효과는, 사용자의 역량이 도구의 효율적 활용과 결합될 때 비판적 사고의 증진으로 이어질 수 있다는 가능성을 보여준다. 비록 본 연구에서 대상자들의 기초 도메인 지식 수준을 변수로 직접 측정하여 그 필수성을 과학적으로 입증한 것은 아니나, 전통적 학습 방식을 거친 현대 프로그래머들의 특성을 고려할 때 이들의 기저 역량이 AI 도구와의 상호작용에서 일정한 역할을 수행했을 개연성을 조심스럽게 추론해 볼 수 있다. 결론적으로 본 연구가 제기한 “생성형 AI가 신입 프로그래머의 성장을 돕는가?” 라는 대주제에 대하여, 본 분석 결과는 AI의 단순한 활용 자체보다는 사용자의 역량적 개입(AI 리터러시)이 성장의 핵심 변수임을 시사한다. 직무만족과 관련된 경로의 기작은 AI가 이미 필수적인 직무 인프라로 안착했음을 투영하고 있으며, 이는 도구의 존재만으로는 더 이상 정서적, 외재적 성장을 담보하기 어려운 환경임을 의미할 여지가 있다. 반면, 리터러시가 높은 집단에서 확인된 비판적 사고의 증진 효과는, AI가 저차원적 과업을 분담함으로써 인간이 고차원적 문제 해결에 집중할 수 있게 돕는 ‘지능적 조력자’로서의 가능성을 보여준다.

따라서 본 연구는 생성형 AI가 신입 프로그래머의 성장에 기여하기 위해서는 탄탄한 기초 도메인 지식과 이를 전략적으로 활용할 수 있는 리터러시 역량이 전제되어야 한다는 ‘조건부적 해답’을 제시하고자 한다. 이러한 관점은 향후 신입 개발자 교육 시스템이 단순한 도구 활용법을 넘어 비판적 검증 역량 강화로 패러다임이 전환되어야 할 필요성을 시사하는 근거로 이해될 수 있다.

본 연구의 결과는 생성형 AI 활용이 단순히 직무 효율을 높인다는 기존의 기술 수용 연구들과 차별화

되는 지점을 시사한다. 기존 연구들이 AI를 통한 성과 향상이라는 동기 요인에 집중했다면, 본 연구는 AI가 이미 신입 개발자들에게 전기나 인터넷과 같은 ‘필수재’이자 ‘위생 요인’으로 전제되어 있음을 밝혀내었다. 특히, 인지적 오프로딩이 사고의 퇴화를 야기한다는 일반적인 우려와 달리, 본 연구에서는 전통적 교육과 AI 실무를 동시에 경험한 과도기적 신입 세대가 AI를 통해 확보된 인지 자원을 고차원적 설계와 검증에 재투자하고 있음을 확인하였다. 이는 AI 의존도를 부정적으로만 보았던 기존의 시각에서 벗어나, 기술 의존이 인지적 태만이 아닌 지능적 협업의 진화로 이어질 수 있는 이론적 근거를 마련했다는 점에서 차별적인 가치를 지닌다.

2. 학술적 시사점

본 연구는 생성형 AI 환경에서 신입 프로그래머의 역량 변화를 실증적으로 규명함으로써 다음과 같은 학술적 시사점을 제공한다.

첫째, 인지적 오프로딩 이론(Theory of Cognitive Offloading)의 논의를 확장하고 재정립하였다. 기존의 선행 연구들은 도구에 대한 인지적 의존이 인간의 기억력 감퇴나 사고력 저하를 초래한다는 부정적 관점에 주로 집중해 왔다. 그러나 본 연구는 인지적 오프로딩이 조건 없는 부정적 기제가 아니며, 사용자의 개인적 역량인 AI 리터러시와 결합할 때 고차원적인 비판적 사고를 촉진하는 ‘전략적 오프로딩’ 기제로 전환될 수 있음을 실증하였다. 이는 도구 사용의 결과가 도구 자체의 속성보다는 사용자의 리터러시 수준이라는 조절 변수에 의해 결정됨을 규명함으로써, 기술 의존에 대한 이분법적 논의를 지양하고 통합적인 관점을 제시했다는 점에서 의의가 있다.

둘째, 정보시스템(IS) 및 교육 공학 분야에서 AI 리터러시의 조절 효과를 방법론적으로 정교하게 검증하였다. 기존의 많은 연구가 조절 변수의 영향력을 검증할 때 단순히 상호작용함의 통계적 유의성만을 확인하는 데 그친 반면, 본 연구

는 절차에 따라 조건부 직접 효과(Conditional Direct Effect)를 검증하는 단순 기울기(Simple Slope) 분석을 수행하였다[51]. 이를 통해 AI 리터러시가 평균 수준이나 낮은 수준일 때와 달리, 높은 수준(+1SD)일 때 비판적 사고가 급격히 향상됨을 구체적인 수치와 기울기로 규명하였다. 이러한 접근은 AI 리터러시가 단순한 선형적 영향 요인이 아니라, 성과 창출을 위한 필수적인 임계 조건(Threshold Condition)임을 밝혀냈다는 점에서 방법론적 기여를 갖는다.

셋째, 직무만족도 결정 요인에 관한 연구 흐름에서 AI 도구의 성격을 재조명하였다. 본 연구 결과, AI 도구 사용과 리터러시는 직무만족도에 유의한 영향을 미치지 않는 것으로 나타났다. 이는 급변하는 IT 개발 환경에서 AI 도구가 개발자의 심리적 만족이나 성취감을 직접적으로 높이는 '동기부여 요인'이라기보다는, 업무 수행을 위해 당연히 갖추어야 할 '기본적인 업무 환경' 또는 '필수재'로 자리 잡았음을 시사한다. 즉, 개발자들에게 AI 도구는 효율적인 업무처리를 위한 필수적인 인프라로 인식될 뿐, 그 도입 자체가 직무만족을 보장하지 않음을 실증적으로 확인하였다. 이는 향후 연구에서 기술적 도구의 단순 도입 여부보다는, 이를 활용한 구체적인 성과 경험이나 조직적 지원과 같은 맥락적 변수를 중요하게 다루어야 함을 제안한다.

이러한 결과는 필수재화 된 AI 환경에서 인지적 오프로딩이 단순히 사고력을 저하시키는 요인이 아니라, 확보된 인지 자원을 고차원적 설계와 검증에 재투입하는 전략적 자원 재배치의 관점에서 재해석될 필요가 있음을 시사한다. 특히 전통적 교육과 AI 실무를 동시에 경험한 과도기적 신입 세대의 데이터를 통해, 기술 의존이 인지적 태만이 아닌 지능적 협업의 진화로 이어질 수 있음을 실증함으로써 기존 인지적 오프로딩 논의를 확장하고 관련 분야 연구에 이론적으로 기여한다.

3. 실무적 시사점

본 연구의 결과는 급변하는 한국 IT 노동시장과 기업의 인재 육성 전략에 대해 다음과 같은 중요한 실무적 시사점을 제공한다.

첫째, 최근 심화되고 있는 신입 개발자 채용 축소 현상이 향후 IT 인력구조의 붕괴를 초래할 수 있음을 경고한다. 최근 경기 침체와 AI 기술의 도입으로 인해 기업들은 비용이 소요되는 신입 개발자의 채용과 교육을 줄이고, 실무에 즉시 투입 가능한 경력직을 선호하거나 AI 자동화 도구로 저숙련 업무를 대체하려는 경향을 보이고 있다. 그러나 본 연구 결과, 인지적 오프로딩이 비판적 사고라는 고차원적 역량으로 이어지기 위해서는 탄탄한 기초 도메인 지식이 필수적임이 밝혀졌다.

현재의 중급 및 고급 개발자들은 과거 신입 시절 직접 코드를 작성하며 시행착오를 겪는 과정을 통해 성장한 세대이다. 만약 기업이 단기적인 효율성만을 추구하여 신입 채용과 훈련 과정을 생략한다면, 향후 AI가 생성한 코드를 검증하고 전체 아키텍처를 설계할 수 있는 검증된 시니어(Verified Senior)의 공급이 중단되는 인력 공백(Hollowing Out) 현상에 직면할 것이다. 따라서 기업은 AI 도구를 도입함과 동시에, 신입 개발자들이 AI에 의존하지 않고 기초 원리를 학습할 수 있는 하이브리드형 온보딩(On-boarding) 프로그램을 강화해야 한다. 이는 단순히 기술을 가르치는 것을 넘어, 미래의 기술 리더를 확보하기 위한 필수적인 투자가 될 것이다.

둘째, AI 시대 개발자의 역할을 단순 코더(Coder)에서 아키텍트(Architect)이자 검증자(Verifier)로 재정의해야 한다. 본 연구 결과, AI 리터러시가 높은 개발자에게 AI는 단순한 업무 대행자가 아니라 사고의 증폭기로 작용함이 확인되었다. 이는 향후 개발자의 핵심 역량이 코드를 빠르게 작성하는 속도가 아니라, AI가 작성한 코드의 논리적 결함을 찾아내고 시스템 전체의 최적화를 판단하는 비판적 검증 능력으로 이동하고 있음을 시사한다.

따라서 기업의 성과 평가 및 채용 방식 또한 변화해야 한다. 단순한 알고리즘 구현 능력보다는 AI 도구를 활용하여 복잡한 문제를 해결하되, 그 결과물의 타당성을 논리적으로 설명할 수 있는 설명 가능한 AI(XAI) 활용 능력을 주요 평가 지표로 삼아야 한다. 이는 AI가 대체할 수 없는 인간 고유의 영역인 설계와 판단 능력을 강화하는 방향으로 조직 문화를 이끌 것이다.

셋째, 교육 기관 및 기업 교육 훈련의 패러다임 전환이 필요하다. 또한, AI 리터러시가 낮은 집단에서 인지적 오프로딩과 비판적 사고의 관계가 통계적으로 유의하지 않게 나타난 점에 주목할 필요가 있다. 이는 AI 도구에 대한 의존이 반드시 비판적 사고의 즉각적인 저하를 초래한다고 단정하기 어려움을 의미한다. 다만, 도구 활용 역량이 뒷받침되지 않을 경우 오프로딩을 통한 고차원적 사고의 확장을 기대하기 어렵다는 점을 확인하였다는 데 의의가 있다. 따라서 기초 원리 습득이 미비한 상태에서의 AI 의존이 가져올 영향에 대해서는 본 연구의 범위를 넘어선 신중한 접근이 요구되며, 향후 연구를 통해 이를 자세히 검토해 볼 필요가 있다. 따라서 대학 및 직무 교육 과정에서는 문법 암기 위주의 교육 비중을 줄이고, AI가 생성한 코드의 오류를 찾아 수정하는 코드 리뷰(Code Review) 훈련과 시스템 설계 역량을 강화하는 방향으로 커리큘럼을 개편해야 한다. 또한, 신입 개발자들이 AI를 무비판적으로 수용하지 않고, 자신의 지식을 바탕으로 AI를 통제하고 활용할 수 있도록 AI 윤리 및 리터러시 교육을 기술 교육과 병행해야 할 것이다.

결론적으로, AI 기술은 인간 개발자를 대체하는 위협이 아니라, 준비된 개발자의 능력을 확장하는 강력한 도구이다. 본 연구는 이러한 공존이 가능하기 위해서는 인간의 기본기(Fundamental)가 유지되어야 하며, 이를 위한 기업과 사회의 지속적인 관심과 투자가 선행되어야 함을 강력히 시사한다. 본 연구는 AI가 필수재로 정착한 환경에서 기업의 교육 방향이 단순한 도구 활용 기술

전수를 넘어, AI와 협력하며 비판적 사고를 유지하는 전략적 리터러시 강화로 전환되어야 함을 강조한다. 이는 신입 직원이 AI를 통해 확보한 인지 자원을 설계 역량 강화나 코드 리뷰와 같은 고차원적 직무 수행에 재투입할 수 있는 실질적인 지침을 제공하며 실무적으로 기여한다.

4. 연구의 한계 및 향후 연구 방향

본 연구는 신입 프로그래머의 AI 도구 활용과 비판적 사고의 관계를 실증적으로 규명하여 유의미한 시사점을 도출하였으나, 다음과 같은 한계점을 가지며 이를 바탕으로 후속 연구를 제안한다.

첫째, 연구 표본이 가진 과도기적(Transitional) 특성에 따른 일반화의 한계이다. 본 연구의 설문 대상은 생성형 AI가 보편화되기 이전에 전통적인 방식으로 프로그래밍 기초 교육을 이수한 후, 실무 진입 단계에서 AI를 접한 세대이다. 이들은 이미 체화된 도메인 지식을 바탕으로 AI를 비판적으로 검증하며 활용할 수 있었다. 그러나 향후 코딩의 기초 원리를 습득하지 않은 상태에서 입문 단계부터 AI 도구에 전적으로 의존하여 학습한 소위 AI 네이티브(AI Native) 세대가 노동시장에 진입했을 때도 본 연구와 동일한 긍정적 결과가 나타날지는 미지수이다. 따라서 후속 연구에서는 학습 배경(전통적 학습자 vs AI 의존적 학습자)이 다른 집단 간의 비교 분석을 통해, AI 도구 활용이 세대별 역량 변화에 미치는 영향을 규명할 필요가 있다.

둘째, 표본의 크기 및 다양성의 제한이다. 본 연구는 PLS-SEM 분석에 필요한 최소 표본 수를 충족하였으나(N=96), 특정 직무(응용 및 시스템 소프트웨어 개발)와 성별(남성 80.2%)에 편중된 경향이 있다. IT 산업 내에서도 프론트엔드, 백엔드, 데이터 엔지니어링 등 세부 직무에 따라 AI 도구의 활용 방식과 의존도는 다를 수 있다. 향후 연구에서는 표본의 크기를 확대하고 다양한 직무군과 성별을 포함하여 연구 결과의 일반화 가

능성을 높여야 할 것이다.

셋째, 횡단적 연구 설계의 한계이다. 본 연구는 특정 시점의 설문 데이터를 바탕으로 변수 간의 관계를 분석하였기에, 인지적 오프로딩이 장기적으로 개발자의 역량에 미치는 인과관계를 단정하기에는 한계가 있다. 단기적으로는 AI 활용이 성과를 높일 수 있으나, 장기적인 의존이 실제 코딩 능력이나 문제 해결 능력의 퇴보를 가져올지에 대해서는 지속적인 관찰이 필요하다. 따라서 향후 연구에서는 종단적(Longitudinal) 연구 설계를 통해 AI 도구 사용 경험의 축적이 개발자의 핵심 역량 변화에 미치는 장기적 영향을 추적해야 할 것이다.

넷째, 자기 보고식(Self-report) 설문의 한계이다. 본 연구는 참여자의 주관적인 인식에 기반하여 변수를 측정하였기에, 실제 비판적 사고 능력이나 직무 성과와는 다소 차이가 있을 수 있다. 후속 연구에서는 실제 코드 리뷰 테스트나 디버깅 과제와 같은 정량적 성과 지표를 도입하거나, 심층 인터뷰(In-depth Interview)와 같은 질적 연구 방법을 병행하여 연구의 타당성을 보완할 것을 제안한다.

REFERENCES

- [1] Sharma, G.G. and K.-J. Stol, Exploring onboarding success, organizational fit, and turnover intention of software professionals. *Journal of Systems and Software*, 2020. vol.159, pp.1-16.
- [2] Wermelinger, M. Using github copilot to solve simple programming problems. in Proceedings of the 54th ACM Technical Symposium on Computer Science Education V. 1. 2023.
- [3] Vaithilingam, P., T. Zhang, and E.L. Glassman. Expectation vs. experience: Evaluating the usability of code generation tools powered by large language models. in Chi conference on human factors in computing systems extended abstracts. 2022.
- [4] Schmitt, A., K.Z. Gajos, and O. Mokryn, Generative AI in the software engineering domain: tensions of occupational identity and patterns of identity protection.arXiv preprint arXiv:2410.03571, 2024.
- [5] Yilmaz, R. and F.G.K. Yilmaz, The effect of generative artificial intelligence (AI)-based tool use on students' computational thinking skills, programming self-efficacy and motivation. *Computers and Education: Artificial Intelligence*, 2023. 4: p. 100147.
- [6] Sweller, J., Cognitive load during problem solving: Effects on learning. *Cognitive science*, 1988. vol.12, no.2, pp. 257-285.
- [7] Risko, E.F. and S.J. Gilbert, Cognitive offloading. *Trends in cognitive sciences*, 2016. vol.20, no.9, pp. 676-688.
- [8] Gerlich, M., AI Tools in Society: Impacts on Cognitive Offloading and the Future of Critical Thinking. *Societies*, 2025. vol.15, no.1, pp. 1-28.
- [9] Grinschgl, S., F. Papenmeier, and H.S. Meyerhoff, Consequences of cognitive offloading: Boosting performance but diminishing memory. *Quarterly Journal of Experimental Psychology*, 2021. vol.74, no.9. pp. 1477-1496.
- [10] Lee, H.-P., et al. The impact of generative AI on critical thinking: Self-reported reductions in cognitive effort and confidence effects from a survey of knowledge workers. in Proceedings of the 2025 CHI conference on human factors in computing systems. 2025.
- [11] Zhai, C., S. Wibowo, and L.D. Li, The effects of over-reliance on AI dialogue systems on students' cognitive abilities: a systematic review. *Smart Learning Environments*, 2024. vol.11, no.28, pp.1-37.
- [12] Zhang, S., Zhao, X., Zhou, T. and Kim, J.H., Do you have AI dependency? The roles of academic self-efficacy, academic stress, and performance expectations on problematic AI usage behavior. *International Journal of Educational Technology in Higher Education*, 2024. vol.21, no.34, pp. 1-14.
- [13] Macnamara, B.N., Berber, I., Çavuşoğlu, M.C., Krupinski, E.A., Nallapareddy, N., Nelson, N.E., Smith, P.J., Does using artificial intelligence assistance accelerate skill decay and hinder skill development without performers' awareness? *Cognitive Research: Principles and Implications*, 2024. vol.9, no.46, pp.1-9.
- [14] Paas, F. and J.J. Van Merriënboer, Cognitive-load theory: Methods to manage working memory load in the learning of complex tasks. *Current Directions in Psychological Science*, 2020. vol.29, no.4, pp. 394-398.
- [15] Sparrow, B., J. Liu, and D.M. Wegner, Google effects on memory: Cognitive consequences of having information at our fingertips. *Science*,

2011. vol.333, no.6043, pp. 776-778.
- [16] Ozturk, N., Assessing metacognition: Theory and practices. *International Journal of Assessment Tools in Education*, 2017. vol.4, no.2, pp. 134-148.
- [17] Long, D. and B. Magerko. What is AI literacy? Competencies and design considerations. in Proceedings of the 2020 CHI conference on human factors in computing systems. 2020.
- [18] Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., and Qiao, M. S., Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, 2021. vol.2, pp.1-11.
- [19] Knoth, Nils, Antonia Tolzin, Andreas Janson, and Jan Marco Leimeister., AI literacy and its implications for prompt engineering strategies. *Computers and Education: Artificial Intelligence*, 2024. vol.6, pp.1-14.
- [20] Sweller, J., Cognitive load theory, in Psychology of learning and motivation. 2011, Elsevier. p. 37-76.
- [21] Klepsch, M. and T. Seufert, Understanding instructional design effects by differentiated measurement of intrinsic, extraneous, and germane cognitive load. *Instructional Science*, 2020. vol.48, no.1, pp. 45-77.
- [22] Skulmowski, A. and K.M. Xu, Understanding cognitive load in digital and online learning: A new perspective on extraneous cognitive load. *Educational psychology review*, 2022. vol.24, no.1, pp. 171-196.
- [23] Chen, O., F. Paas, and J. Sweller, A cognitive load theory approach to defining and measuring task complexity through element interactivity. *Educational Psychology Review*, 2023. vol.35, no.63, pp.1-18.
- [24] Fan, G., et al., The impact of AI-assisted pair programming on student motivation, programming anxiety, collaborative learning, and programming performance: a comparative study with traditional pair programming and individual approaches. *International Journal of STEM Education*, 2025. vol.12, no.16, pp.1-17.
- [25] Fisher, M., A.H. Smiley, and T.L. Grillo, Information without knowledge: The effects of Internet search on learning, in Memory Online. 2022, Routledge. p. 7-19.
- [26] Bailin, S. and H. Siegel, Critical thinking. *The Blackwell guide to the philosophy of education*, 2003: p. 181-193.
- [27] Lai, E.R., Critical thinking: A literature review. *Pearson's research reports*, 2011. vol.6, no.1, pp. 40-41.
- [28] Giering, O. and S. Kirchner, Artificial intelligence and autonomy at work: empirical insights from Germany. *Journal for Labour Market Research*, 2025. vol.59, no.20, pp.1-15.
- [29] Akdur, G., M.N. Aydin, and G. Akdur, Understanding Virtual Onboarding Dynamics and Developer Turnover Intentions in the Era of Major Global Forces. Available at SSRN 4549492, 2023.
- [30] Chuang, Y.-T., H.-L. Chiang, and A.-P. Lin, Insights from the Job Demands - Resources Model: AI's dual impact on employees' work and life well-being. *International Journal of Information Management*, 2025. vol.83, pp.1-17.
- [31] Zhang, Zhe, Xiping Wang, Chang Su, Xiaohan Zhang, Linhui Sun, and Xiaofang Yuan., Technostress and employee safety performance in China: The moderating role of perceived organizational support and the mediating role of job burnout. *Journal of General Management*, 2024: vol.1.
- [32] Pinski, M. and A. Benlian, AI literacy-towards measuring human competency in artificial intelligence. 2023.
- [33] Veenman, M.V., B.H. Van Hout-Wolters, and P. Afflerbach, Metacognition and learning: Conceptual and methodological considerations. *Metacognition and learning*, 2006. 1(1): p. 3-14.
- [34] Fleming, S.M., Metacognition and confidence: A review and synthesis. *Annual Review of Psychology*, 2024. vol.75, no.1, pp. 241-268.
- [35] Bewersdorff, Arne, Marie Hornberger, Claudia Nerdel, and Daniel S. Schiff., AI advocates and cautious critics: How AI attitudes, AI interest, use of AI, and AI literacy build university students' AI self-efficacy. *Computers and Education: Artificial Intelligence*, 2025. vol. 8.
- [36] Du, Hua, Yanchao Sun, Haozhe Jiang, A. Y. M. Islam, and Xiaoqing Gu. , Exploring the effects of AI literacy in teacher learning: An empirical study. *Humanities and social sciences communications*, 2024. vol.11, no.1, pp. 1-10.
- [37] Kuvaas, B., Work performance, affective commitment, and work motivation: The roles of pay administration and pay level. *Journal of Organizational Behavior: The International Journal of Industrial, Occupational and Organizational Psychology and Behavior*, 2006. vol.27, no.3, pp. 365-385.
- [38] Williams, Margaret L., Holly H. Brower, Lucy R. Ford, Larry J. Williams, and Shawn M. Carraher., A comprehensive model and measure of compensation satisfaction. *Journal of Occupational*

and *Organizational Psychology*, 2008. vol.81, no.4, pp. 639-668.

- [39] Lee, C.H. and N.T. Bruvold, Creating value for employees: investment in employee development. *The International Journal of Human Resource Management*, 2003. vol.14, no.6, pp. 981-1000.
- [40] Eisenberger, R., Huntington, R., Hutchison, S., and Sowa, D., Perceived organizational support. *Journal of Applied psychology*, 1986. vol.71, no.3, pp.500-507.
- [41] Sweller, J., Cognitive load theory and educational technology. *Educational technology research and development*, 2020. vol.68, no.1, pp. 1-16.
- [42] Evans, P., Vansteenkiste, M., Parker, P., Kingsford-Smith, A. and Zhou, S., Cognitive load theory and its relationships with motivation: A self-determination theory perspective. *Educational Psychology Review*, 2024. vol.46, no.7, pp.1-25.
- [43] Dreyfus, S.E. and H.L. Dreyfus, A five-stage model of the mental activities involved in directed skill acquisition. 1980.
- [44] 대한민국, 소프트웨어산업 진흥법 시행령. 2012, 국가법령정보센터.
- [45] 한국소프트웨어산업협회, S/W기술자 평균임금 및 노임단가 산정기준. 2019년
- [46] 최희선, 김주영, and 조진환, 산업기술인력의 경력 경로에 관한 연구: 소프트웨어산업을 중심으로. 서울: 산업연구원, 2012년
- [47] Hair, Joseph F., William C. Black, Barry J. Babin, and Rolph E., *Multivariate Data Analysis*. 2019: Cengage.
- [48] Fornell, C. and D.F. Larcker, Evaluating structural equation models with unobservable variables and measurement error. *Journal of marketing research*, 1981. vol.18, no.1, pp. 39-50.
- [49] Kock, N., Common method bias in PLS-SEM: A full collinearity assessment approach. *International Journal of e-Collaboration*, 2015. vol.11, no.4, pp. 1-10.
- [50] Henseler, J., C.M. Ringle, and M. Sarstedt, A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the academy of marketing science*, 2015. vol.43, no.1, pp. 115-135.
- [51] Hair, J., et al., *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)*. 2021: SAGE Publications.

저자 소개



전광섭(준회원)

2018: 아주대학교 경영대학원 MBA석사

2011~현재: 아이엔티로보틱스 대표이사
<주관심분야: 로보틱스, 생성형 AI, 자동화, 인공지능>



이한솔(정회원)

2015: 아주대학교 학사

2022: 아주대학교 박사

2025.3 ~ (현재) 아주대학교 경영대학
글로벌경영학과 조교수

<주관심분야: 계량경제, 최적화, 빅데이터>



강주영(정회원)

1995: 포항공과대학교 학사

1997: 서울대학교 석사

2005: 한국과학기술원 박사

<주관심분야: 생성형 AI, LLM, 텍스트마이닝, 빅데이터, 인공지능, 지능정보시스템, 블록체인>