

생성형 AI 기반 비주얼 노벨 저작 도구의 제작 효율 인식과 워크플로우 재설계

김 태 완¹ · 김 태 훈^{2*}¹서강대학교 가상융합전문대학원 테크놀로지 전공 박사과정²서강대학교 가상융합전문대학원 조교수

Perceived Production Efficiency and Workflow Redesign in a Generative AI-Based Visual Novel Authoring Tool

Taewan Kim¹ · Taehoon Kim^{2*}¹Ph.D. Program, Graduate School of Virtual Convergence, Sogang University, Seoul 04107, Korea²Professor Graduate School of Virtual Convergence, Sogang University, Seoul 04107, Korea

[요 약]

비주얼 노벨 제작은 기획·아트·스크립트·엔진 빌드의 다단계 수작업 공정으로, 도구 전환과 반복 작업이 주요 병목현상으로 인식된다. 본 연구는 자연어 입력부터 엔진 빌드까지 단일 파이프라인으로 통합된 AI 기반 저작 도구 'VN-AI Studio'를 대상으로, 실제 사용자(N=155)의 제작 효율 인식과 재사용 의도를 분석하였다. 대응표본 t-검정 결과 기존 대비 평균 97.7% 시간 단축이 확인됐으며($t=8.565$, $p<.001$, Cohen's $d=0.690$), 응답자 74.2%가 결과물 수정 필요성을 20% 미만으로 평가했다. 회귀 분석에서 생산성 인식이 재사용 의향의 39.9%를 설명하는 핵심 변수($\beta=0.677$, $p<.001$)로 나타났고, 인지 부하는 부적 영향을 미쳤다($\beta=-0.291$, $p<.001$). 게임 개발 경험 수준에 따른 효율 인식 차이는 유의하지 않았다($F=0.276$, $p=.843$). 이 결과는 AI 통합 도구가 단순 결합을 넘어 제작 공정을 재설계하는 AI-Native Pipeline으로 작동할 수 있음을 보여주며, 소규모 팀과 비전문가 환경에서도 게임 제작 확장가능성을 시사한다.

[Abstract]

Visual novel production is a labor-intensive, multistage process involving planning, art, scripting, and engine building, with tool switching and repetition serving as major bottlenecks. This study analyzed the perceived efficiency and reuse intention among 155 users of VN-AI Studio, an artificial intelligence (AI)-based authoring tool that integrates the full pipeline from natural language prompts to final engine builds. Paired t-test results showed a 97.7% average reduction in production time ($t = 8.565$, $p < 0.001$). Approximately 74.2% of participants reported needing less than 20% manual modification of AI outputs. Regression analysis indicated perceived productivity as the key predictor of reuse intention ($\beta = 0.677$, $p < 0.001$), and cognitive load had a significant negative impact ($\beta = -0.291$, $p < 0.001$). Meanwhile, game development experience level showed no significant effect ($F = 0.276$, $p = 0.843$). These findings demonstrate that AI-integrated tools can function as an AI-Native Pipeline, redesigning the creation process and expanding access for small teams and nonexperts.

색인어 : 생성형 AI, 비주얼 노벨, AI 저작 도구, 제작 효율 인식, 워크플로우 재설계**Keyword** : Generative AI, Visual Novel, AI Authoring Tool, Perceived Production Efficiency, Workflow Redesign<http://dx.doi.org/10.9728/dcs.2026.27.5.1401>

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 24 March 2026; Revised 10 April 2026

Accepted 27 April 2026

*Corresponding Author; Taehoon Kim

Tel: +82-2-705-8902

E-mail: taehoonkim@sogang.ac.kr

1. 서론

1-1 게임 제작 환경의 구조적 문제

비주얼 노벨은 시나리오 집필, 캐릭터 및 배경 에셋 제작, 엔진 스크립트 작성, 최종 빌드에 이르는 다단계 공정을 요구하는 인터랙티브 콘텐츠 장르이다. 각 단계는 서로 이질적인 전문 도구와 기술 역량을 전제로 분절되어 운영되며, 공정 간 전환 과정에서 발생하는 도구 전환 비용(Tool-Switching Cost)과 반복 수작업에 따른 병목은 제작 효율을 저하시키는 구조적 요인으로 작용한다[1]. 예를 들어 시나리오 텍스트를 이미지 생성 도구로 전달하고 결과물을 엔진 스크립트에 수동 입력하는 과정은 파일 포맷 변환, 경로 설정, 리네이밍 등 반복 작업을 수반한다. 이러한 공정 분절 구조는 개별 단계 오류가 후속 공정 전체에 연쇄적으로 영향을 미치는 취약한 종속 구조를 형성하며 제작 사이클을 비효율적으로 만든다. 공정이 분절될수록 창작자는 서사 연출보다 기술적 수행에 더 많은 인지 자원을 소모해 창의적 완성도 저하로 이어질 수 있으므로 구조적 개선이 필요하다

이러한 분절 구조의 부담은 소규모 팀이나 1인 개발 환경에서 특히 심각하게 나타난다. 소규모 창작 환경에서는 기획자가 아트 제작, 코딩, 연출 등 다수의 전문 영역을 동시에 담당해야 하는 경우가 빈번하며, 이는 창작 의도의 실현보다 기술적 수행에 더 많은 자원이 소요되는 역전 현상을 낳는다[2]. 이는 전체 제작 사이클에서 창작적 의사결정 비중은 낮아지고 반복 수작업 시간이 지배적이 된다. 본 연구 설문(N=155)에 따르면 응답자의 30.3%가 3분 분량 비주얼 노벨 제작에 6시간 이상, 14.2%는 3일 이상이 소요될 것으로 예상했다. 이는 공정 분절 구조가 높은 시간 비용으로 인식되고 있음을 보여주며, 통합 도구 환경 없이는 제작 진입 장벽이 높게 유지됨을 시사한다. 전문 개발자뿐 아니라 비전문 창작자들이 인터랙티브 콘텐츠를 실질적으로 제작하려면 공정 구조의 근본적 변화가 필요하며, 이를 위한 기술적 해법 탐색이 본 연구의 출발점이 된다.

1-2 생성형 AI 도입의 한계

생성형 AI의 급속한 발전은 게임 제작 영역에도 변화를 가져왔다. ChatGPT를 활용한 시나리오 초안 생성, Midjourney나 Stable Diffusion을 활용한 에셋 제작 등 개별 AI 도구의 활용이 빠르게 확산되고 있으나, 이러한 방식은 도구 간 통합 없이 각 단계를 개별적으로 처리하는 Tool Adoption 수준에 머물러 있다는 근본적 한계를 지닌다[3],[4]. 이 방식에서 창작자는 여전히 각 도구 사이를 이동하는 중간자 역할을 수행해야 하며, 프롬프트 추출, 이미지 생성, 파일 다운로드 및 리네이밍, 엔진 스크립트 수동 작성의 최소 4단계 이상 수동 개입이 여전히 필수적이다. 결과적으로

파이프라인 단절에 따른 제작 비효율 문제는 AI 도입 이후에도 구조적으로 지속되며, 개별 도구의 생성 속도 향상이 전체 공정의 효율 개선으로 이어지지 않는 역설적 상황이 발생한다. 특히 이미지 생성 AI는 동일한 프롬프트에서도 캐릭터 외형이 매 생성마다 달라지는 아이덴티티 표류(Identity Drifting) 문제를 발생시키며, 이를 수작업으로 보정하거나 LoRA 파인튜닝으로 해결하기 위한 후처리 비용이 상당하여 실무 적용에 추가적인 장벽을 형성한다.

이는 AI 도입이 공정의 일부를 가속할 수는 있으나, 워크플로우 전체를 재설계하는 Process Re-engineering으로 이어지지 않는 한 구조적 병목을 근본적으로 제거하기 어려움이 있으며 단일 파이프라인 기반 통합 저작 환경에 대한 필요성을 더욱 강조한다[5],[6]. 표 1은 전통적 수작업 방식, 범용 AI 도구의 파편적 활용 방식, 통합 파이프라인 방식의 워크플로우 효율성을 공정 구조, 소요 시간, 일관성, 요구 역량의 네 가지 차원에서 비교하여 제시한다. 세 방식의 비교를 통해 통합 파이프라인이 단순 속도 향상을 넘어 공정 구조 자체를 단순화하고 진입 요건을 낮추는 질적 전환임을 확인할 수 있으며, 이러한 통합 접근의 실효성을 사용자 인식 관점에서 실증하는 것이 본 연구의 핵심 목표이다.

표 1. 생성 방법 별 워크플로우 효율성 비교

Table 1. Comparison of workflow efficiency by production method

| Criteria | ① Traditional | ② Fragmented AI | ③ VN-AI Studio |
|-------------|--------------------|--------------------|------------------|
| Process | Plan→Art→Edit→Code | Gen→Save→Edit→Code | Input→Auto→Build |
| Time | High (Days/Scene) | Medium (Slow Edit) | Low (Real-time) |
| Consistency | High (Labor) | Low (ID Drifting) | High (Anchor) |
| Skills | Expert | Prompt + Code | Planning only |
| Steps/scene | 4+ manual | 4+ manual | 1 pipeline |

1-3 연구 목적 및 구성

이러한 문제의식에서 본 연구는 자연어 입력부터 엔진 빌드까지 전 과정을 단일 파이프라인으로 통합한 AI 기반 저작 도구 ‘VN-AI Studio’를 대상으로, 실제 사용자(N=155)의 제작 효율 인식 구조와 채택 결정 요인을 실증적으로 분석하는 것을 목적으로 한다. 구체적으로는 세 가지 연구 문제를 설정하였다. 첫째, AI 통합 파이프라인 도입이 기존 방식 대비 제작 시간 인식에 어떠한 변화를 가져오는가? 둘째, 생산성 인식, 사용 용이성, 제작속도 인식, 인지 부하는 도구 재사용 의향에 각각 어떠한 영향을 미치는가? 셋째, 게임 개발 경험 수준에 따라 제작 효율 인식에 유의한 집단 간 차이가 나타나는가? 이를 통해 본 연구는 AI 통합 저작 도구의 실효성을 사용자 인식 데이터로 실증하는 동시에, 도구 채택 구조에 영향을 미치는 핵심 요인을 규명하고자 한다.

본 논문의 이후 구성은 다음과 같다. 2장에서는 비주얼 노벨 제작 공정 및 AI 통합 모델에 관한 이론적 배경을 검토하고, 3장에서는 연구 설계 및 분석 방법을 기술한다. 4장에서는 주요 분석 결과를 제시하며, 5장에서는 산업적 시사점을, 6장에서는 결론 및 향후 연구 방향을 논의한다. 본 연구는 VN-AI Studio의 기술적 구현이나 알고리즘 설계 보다는 실제 사용자의 인식 데이터를 기반으로 AI 통합 제작 도구의 효율 인식 구조와 채택 결정 요인을 실증적으로 검증하는 사용자 인식 기반 실증 연구를 밝힌다. 이는 선행 연구에서 개념적으로 제안된 AI-Native Pipeline의 실무적 유효성을 사용자 관점에서 독립적으로 확인한다는 점에서 연구 시리즈의 최종 검증 단계를 구성한다.

II. 게임 제작 파이프라인과 AI 통합 모델

2-1 전통적 비주얼 노벨 제작 공정

비주얼 노벨 제작 공정은 기획, 아트, 스크립트, 빌드의 4 단계 선형 구조로 구성된다. 기획 단계에서는 세계관 설정, 캐릭터 구성, 시나리오 집필, 분기 구조 설계가 이루어지며, 아트 단계에서는 캐릭터 스탠딩 CG, 배경 이미지, UI 에셋이 제작된다. 스크립트 단계에서는 Ren'Py, Kirikiri 등 엔진 문법에 따라 대화문, 분기 로직, 에셋 호출 코드가 작성되고, 빌드 단계에서는 모든 요소를 통합하여 최종 실행 패키지가 생성된다. 이 네 단계는 각각 독립된 소프트웨어 생태계를 전제로 하므로 단계 간 데이터 전환은 수동 변환만으로 이루어진다. 순차적 선형 구조는 초기 기획 변경이 후속 아트 및 스크립트 전체에 파급되는 취약성을 내포하며, 캐릭터별 표정·자세 변화에 따라 수십 종 이미지를 개별 제작·관리하는 반복 노동이 수반된다. 전통적 공정의 진입 장벽은 각 단계의 전문성 의존도에서 비롯된다. 시나리오 작성에는 서사 구조와 분기 설계 능력이, 아트 제작에는 디지털 드로잉 역량이, 엔진 스크립트 작성에는 프로그래밍 이해가 각각 요구되므로, 한 인물이 전체 공정을 담당하려면 다영역 전문성이 필요하다. 이는 소규모 인디 팀이나 교육 현장에서 비주얼 노벨 제작을 시도할 때 가장 현실적인 장벽으로 작용하며, 프로젝트 규모가 클수록 분업 체계를 유지하기 위한 인력 비용과 조율 비용이 함께 증가한다는 문제도 동반한다[1],[2]. 아울러 특정 장면에서 캐릭터 표정을 수정하거나 새로운 분기를 추가할 경우, 연결된 모든 스크립트 참조를 일관되게 업데이트해야 하는 종속 수정 작업이 발생하여 유지보수 비용 또한 상당하다. 이러한 구조적 특성은 제작 규모가 커질수록 복잡성이 기하급수적으로 증가하며, 프로젝트 완성도와 일관성 확보를 어렵게 만드는 핵심 요인으로 지목된다[7].

2-2 AI 도입 방식의 비교: Tool Adoption과 Process Re-Engineering

생성형 AI의 게임 제작 활용 방식은 도구 수용 수준에 따라 Tool Adoption과 Process Re-engineering의 두 유형으로 구분할 수 있다. Tool Adoption은 ChatGPT, Midjourney 등 개별 도구를 각 공정 단계에 부분적으로 적용하는 방식으로, 생성 속도는 향상되지만 도구 간 통합이 없어 수동 개입과 파이프라인 단절이 지속된다[8]. 이 방식에서 창작자는 각 도구 사이의 중간자 역할을 여전히 수행해야 하며, 생성된 결과물의 형식 변환, 파일 리네이밍, 엔진 연동 등의 반복 작업은 근본적으로 해소되지 않는다. 특히 AI 이미지 생성 모델에서 빈번히 나타나는 아이덴티티 표류 현상은 Tool Adoption 방식의 핵심 한계로, 이를 극복하기 위한 수작업 리터칭이나 LoRA 파인튜닝이라는 고비용 후처리 과정이 추가로 요구된다[9]. 결국 개별 도구 생산성 향상이 전체 공정 효율 개선으로 이어지지 않는 구조적 역설이 발생하며, AI 도입 전후 효율 차이가 미미한 경우도 흔하다. 반면 Process Re-engineering은 AI를 공정 전체의 핵심 요소로 내재화해 워크플로우 자체를 근본적으로 재설계한다. 전자는 기존 공정의 특정 단계만 부분적으로 가속하는 반면, 후자는 단계 간 수동 전환 자체를 제거해 병목 구조를 구조적으로 해소하므로 제작 효율 영향이 질적으로 다르다. 이는 제작 시간 단축을 넘어 창작자가 기술적 수행 부담에서 벗어나 서사 연출과 창작적 의사결정에 집중할 수 있는 환경을 만들어 사용자 경험 전반에도 긍정적 영향을 미친다. 비전문가 환경에서는 Tool Adoption 방식이 오히려 도구 학습 비용을 증가시켜 진입 장벽을 높일 수 있는 반면, 통합 파이프라인은 단일 인터페이스로 전체 공정을 처리함으로써 기술 의존도를 낮추고 접근성을 실질적으로 확대하는 효과를 가져온다[10].

2-3 AI-Native Pipeline의 개념과 제작 효율 인식

AI-Native Pipeline은 자연어 입력부터 실행 가능한 빌드까지 전 과정이 단일 자동화 흐름으로 끊임없이 연결된 제작 환경을 의미한다. 기존의 도구 전환 방식과 달리, AI-Native Pipeline에서는 사용자의 자연어 의도가 시스템 내부에서 서사 구조화, 에셋 생성, 엔진 컴파일의 세 과정을 자동으로 거쳐 실행 가능한 결과물로 변환된다. 이 구조에서 사용자는 기술적 수행 대신 창작 의도에 집중할 수 있으며, 이는 제작 효율 인식과 도구 채택 의향에 직접적인 영향을 미친다. 선행 연구들은 통합 파이프라인이 반복 작업을 자동화함으로써 창작자가 고차원적인 서사 설계와 연출 결정에 더 많은 인지 자원을 투입할 수 있도록 돕는다고 제안하며, 이는 제작 생산성뿐 아니라 결과물의 서사적 완성도 향상에도 기여하는 이중 효과로 이어진다[11]. 본 연구에서 분석 대상으로 삼은 VN-AI Studio는 세 가지 핵심 기제를 통해 AI-Native

Pipeline을 구현하였다. 첫째, 기승전결 4단계 계층적 클러스터링 구조를 통해 LLM의 환각(Hallucination) 및 서사 축소 경향을 프롬프트 설계 수준에서 구조적으로 억제한다. 둘째, Google Imagen의 참조 이미지 기능을 활용한 페르소나 앵커(Persona Anchor) 기법으로 고비용 파인튜닝 없이도 캐릭터 시각 일관성을 확보한다. 셋째, JSON 스키마 기반 단일 파이프라인을 통해 생성된 서사와 에셋을 Ren'Py 엔진 스크립트로 자동 컴파일하여 코딩 없이 실행 가능한 빌드를 산출한다. 본 연구는 이 시스템에 대한 실제 사용자의 효율 인식 구조와 채택 결정 요인을 실증적으로 분석함으로써, 선행 연구의 설계·구현 결과를 사용자 데이터로 검증하는 연구 시리즈의 최종 단계를 구성하는 동시에, AI-Native Pipeline이 실무 환경에서 유효하게 작동하는지를 사용자 관점에서 독립적으로 확인한다.

III. 연구 설계 및 분석 방법

3-1 연구 대상 및 표본 특성

본 연구는 VN-AI Studio를 직접 사용한 경험이 있는 응답자를 대상으로 온라인 설문을 실시하였다. 총 173건의 응답 중 전화번호 입력란에 이메일 주소를 기입하는 패턴을 보인 18건을 봇(Bot) 응답으로 판별하여 제외하고, 최종 유효 표본 N=155를 분석에 활용하였다. 표본의 성별 구성은 여성 80명(51.6%), 남성 74명(47.7%)이며, 연령대는 20대 44.5%, 30대 41.9%가 전체의 86.4%를 차지하였다. 직무 구성은 프로그래밍·엔지니어링 31.6%, 아트·디자인 29.7%, 게임 기획·시나리오 22.6%, 연구·학술 13.5%로, 현업 종사자 및 관련 전공자가 표본의 대다수를 구성하였다. 게임 개발 경험은 1~3년이 41.9%로 가장 많았으며, 3년 이상 경력자도 29.0%에 달하여 표본의 약 71%가 실질적인 개발 경험을 보유하고 있음을 확인하였다. 표 2는 표본의 인구통계학적 특성 전체를 정리하여 제시한다. AI 사용 빈도 측면에서는 매일 사용한다는 응답이 46.5%로 가장 높았으며, 주 1회 이상 사용자가 전체의 88.4%를 차지하여 표본의 AI 친숙도가 전반적으로 높은 편이었다. 이러한 표본 특성은 생성형 AI 기반 저작 도구에 대한 실질적인 사용 경험과 평가 역량을 갖춘 집단이지만, 본 연구의 표본은 VN-AI Studio 실사용 경험자로 한정되었으며, 이는 도구 사용 효과를 직접 경험한 집단의 인식 구조를 분석하기 위한 의도적 표집임을 밝힌다. 따라서 본 결과는 도구 미사용자 또는 일반 게임 개발자 전체로의 직접적 일반화에는 한계가 있으며, 초기 사용자 긍정 편향의 가능성도 완전히 배제할 수 없는 한계가 있다.

표 2. 연구 참여자 인구통계학적 특성(N = 155)

Table 2. Demographic characteristics of participants (N = 155)

| Variable / Category | n | % |
|---------------------|-----|-------|
| Gender | | |
| Female | 80 | 51.6 |
| Male | 74 | 47.7 |
| Other | 1 | 0.6 |
| Age | | |
| 20s | 69 | 44.5 |
| 30s | 65 | 41.9 |
| 40s | 15 | 9.7 |
| 50+ | 5 | 3.2 |
| Job | | |
| Programming | 49 | 31.6 |
| Art / Design | 46 | 29.7 |
| Game Planning | 35 | 22.6 |
| Research | 21 | 13.5 |
| Other | 3 | 1.9 |
| Experience | | |
| None | 11 | 7.1 |
| < 1 year | 33 | 21.3 |
| 1-3 years | 65 | 41.9 |
| 3+ years | 45 | 29.0 |
| AI Use Freq. | | |
| Daily | 72 | 46.5 |
| 3-4x/week | 37 | 23.9 |
| 1-2x/week | 28 | 18.1 |
| <1x/week | 17 | 11.0 |
| Total | 155 | 100.0 |

3-2 실험 조건 및 제작 환경

본 연구의 설문 참여자는 VN-AI Studio를 활용하여 지정된 조건 하에 비주얼 노벨을 직접 제작한 후 응답하였다. 제작 조건은 다음과 같이 설정되었다: ① 분량 조건: 3분 플레이 분량(8~12장면, 선택 분기 2개 이상 포함), ② 주제 조건: 자유 주제(응답자가 세계관 및 캐릭터 직접 설정), ③ 도구 조건: VN-AI Studio 웹 인터페이스만 사용(외부 AI 도구 병행 불허), ④ 완성 기준: Ren'Py 엔진 빌드까지 완료된 플레이 가능 상태. 제작 프로세스는 기승전결(起承轉結) 4단계 Story Flow 구조를 따르며, ① 프로젝트 주제 입력 → ② 캐릭터 및 페르소나 설정 → ③ 장면별 대화 시나리오 AI 자동완성 → ④ 배경 이미지 AI 생성 → ⑤ Ren'Py 자동 빌드의 5단계 단일 파이프라인으로 구성된다. 그림 1은 VN-AI Studio의 저작 인터페이스를, 그림 2는 실제 생성된 비주얼 노벨 플레이 화면 예시를 제시한다. 실제 생성된 게임의 장르는 판타지, SF, 로맨스, 공포, 추리 등 다양하게 분포하였으며(Q44), 이는 자유 주제 조건 하에서 시스템이 다양한 서사 유형에 적용 가능함을 시사한다.

3-3 변수 구성 및 측정 도구

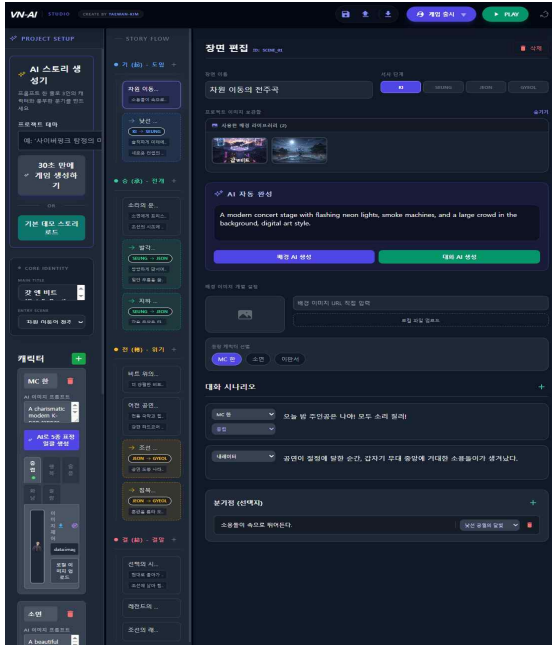
설문은 7점 리커트 척도(1=전혀 그렇지 않다, 7=매우 그렇다) 기반 총 31개 문항으로 구성되었으며, 9개 구인으로 조작화하였다. 제작속도 인식(Q6)은 단일 문항으로 측정하였으며, 생산성 인식(Q7-9), 사용 용이성(Q10-13), 출력 품질 인식(Q14-17), 창의성 지원(Q18-21), 재사용 의향(Q22-24), 교육적 유용성(Q25-27), 창작 주도권(Q28-33), 인지 부하(Q34-36)는 복수 문항으로 구성하였다. 이에 더하여 기존 방식 예상 소요 시간(Q37)과 VN-AI Studio 실제 소요 시간(Q38), 그리고 AI 인식 방식 유형(Q40)이 포함되었다. 인지 부하 문항은 역방향 해석으로 원점수를 그대로 활용하였으며, 점수가 높을수록 부하가 크다고 해석된다. 각 구인은 도구의 기능적 특성과 사용자 경험의 주요 차원을 포괄적으로 측정하도록 설계되었으며, TAM(Technology Acceptance Model) 기반 선행 연구의 측정 문항을 비주얼 노벨 제작 도구의 맥락에 맞게 수정·적용하였다.

신뢰도 분석 결과 인지 부하($\alpha=.848$), 창작 주도권($\alpha=.796$), 출력 품질 인식($\alpha=.768$)은 양호한 수준을 보였으며, 교육적 유용성($\alpha=.701$)과 창의성 지원($\alpha=.679$)도 수용 가능한 범위에 해당하였다. 반면 생산성 인식($\alpha=.474$), 사용 용이성($\alpha=.581$), 재사용 의향($\alpha=.585$)은 일반적 기준치($\alpha=.60$)에 미달하였으며, 이는 문항이 각각 3~4개로 구성된 짧은 척도에서 나타날 수 있는 제한적 신뢰도 문제로 판단된다. 해당 구인들은 결과 해석 시 탐색적 분석 수준으로 제한하여 보고하였으며, 향후 연구에서 문항을 정교화하고 확인적 요인분석을 통해 구인 타당도를 재검증할 필요가 있다. 표 3은 각 구인의 문항 수, 평균, 표준편차, 신뢰도 계수를 제시한다. α 미달 구인(생산성 인식, 사용 용이성, 재사용 의향)을 포함한 회귀 분석 결과는 변수 간 관계의 탐색적 경향 확인으로 제한 해석

표 3. 구성 개념별 기술통계 및 신뢰도 계수

Table 3. Descriptive statistics and reliability coefficients by construct

| Construct (Items) | N | M | SD | α |
|--------------------------------|-----|------|------|----------|
| Educational Utility (Q25-27) | 155 | 5.80 | 0.88 | .701 |
| Creativity Support (Q18-21) | 155 | 5.74 | 0.78 | .679 |
| Production Speed (Q6) | 155 | 5.71 | 1.20 | — |
| Ease of Use (Q10-13) | 155 | 5.65 | 0.80 | .581* |
| Productivity Perception (Q7-9) | 155 | 5.64 | 0.85 | .474* |
| Output Quality (Q14-17) | 155 | 5.63 | 0.98 | .768 |
| Reuse Intention (Q22-24) | 155 | 5.60 | 0.85 | .585* |
| Creative Autonomy (Q28-33) | 155 | 5.41 | 0.86 | .796 |
| Cognitive Load (Q34-36) | 155 | 2.61 | 1.30 | .848 |



*Interface text shown in Korean to reflect the original application environment

그림 1. VN-AI Studio 저작 인터페이스

Fig. 1. VN-AI Studio authoring interface



*Interface text shown in Korean to reflect the original application environment

그림 2. VN-AI Studio 생성 결과물 예시

Fig. 2. Sample outputs generated by VN-AI Studio

되어야 하며, 확정적 인과 관계의 근거로 사용되어서는 안 된다. 향후 문항 구성의 정교화와 확인적 요인분석(CFA)을 통해 구인 타당도를 보완할 예정이다.

3-4 분석 방법

수집된 데이터는 IBM SPSS Statistics 27.0을 활용하여 단계적으로 분석하였다. 먼저 Cronbach's α 를 통한 신뢰도 분석으로 측정 도구의 내적 일관성을 검토하였다. 다음으로 제작 시간 인식 변화를 확인하기 위해 기존 방식 예상 소요 시간(Q37)과 VN-AI Studio 실제 소요 시간(Q38)을 대응표본 t-검정으로 비교하였다. 이후 각 구인이 재사용 의향에 미치는 영향을 파악하기 위해 생산성 인식, 사용 용이성, 제작속도 인식, 인지 부하를 독립변수로 하는 단순회귀분석을 각각 수행하였다. 단순회귀 방식을 채택한 것은, 본 연구가 각 예측 변수의 독립적 설명력을 탐색적으로 확인하는 초기 단계 연구이기 때문이다. 본 연구는 TAM을 완전히 구현하는 것이 아니라, TAM의 핵심 변수(지각된 유용성, 지각된 용이성)를 참조하여 AI 저작 도구 맥락에 적용한 탐색적 연구를 밝힌다. 변수 간 상호작용 및 매개 구조 검증은 향후 다중회귀 및 구조방정식 모형(SEM)으로 확장할 예정이다.

마지막으로 게임 개발 경험 수준(4집단: 경험 없음, 1년 미만, 1~3년, 3년 이상)에 따른 제작 효율 인식 차이를 일원분산분석(one-way ANOVA)으로 검증하였으며, 통계적으로 유의한 경우 Tukey HSD 사후 검정을 실시하였다. 효과크기는 대응표본 t-검정에 대해 Cohen's d, 분산분석에 대해 η^2 으로 산출하였으며, 단순회귀분석에서는 표준화 회귀계수(β)와 결정계수(R^2)를 주요 지표로 보고하였다. 통계적 유의수준은 $\alpha=.05$ 로 설정하였다. 단, 기존 방식 예상 소요 시간(Q37)은 응답자의 주관적 인식에 기반한 추정치이며, VN-AI Studio 실제 소요 시간(Q38)과는 측정 조건이 상이하다. 따라서 두 값의 비교는 절대적 시간 효율의 객관적 측정이 아닌, 사용자 인식 수준에서의 제작 시간 변화를 분석하는 것임을 밝힌다.

IV. 분석 결과

4-1 제작 시간 인식 변화

기존 방식으로 3분 분량의 비주얼 노벨을 제작할 경우 예상 소요 시간은 평균 994.3분($SD=1434.0$)으로 나타난 반면, VN-AI Studio를 실제 사용한 소요 시간은 평균 4.6분($SD=3.1$)에 불과하였다. 대응표본 t-검정 결과 두 조건 간 차이는 통계적으로 매우 유의하였으며($t=8.565$, $df=153$, $p<.001$), 평균 제작 시간 인식 변화는 97.7%로 Cohen's $d=0.690$ 의 중간~높은 수준의 효과크기를 보였다. 이는 AI 통합 파이프라인이 제작 시간을 단순히 단축하는 수준을 넘

어, 공정의 구조적 전환을 이끌어낼 수 있는 실질적 역량을 보유하고 있음을 시사한다. 특히 기존 방식의 표준편차($SD=1434.0$)가 매우 크다는 점은 응답자별 예상 시간의 편차가 극심하여 숙련도 의존성이 높음을 보여주며, 이에 반해 VN-AI Studio의 낮은 표준편차($SD=3.1$)는 도구 사용 결과가 사용자의 숙련도와 무관하게 일관된 시간 내에 수렴함을 의미한다. 표 6 및 그림 3은 두 조건의 소요 시간 분포를 비교하여 제시한다.

생성 결과물의 실용성 측면에서 응답자의 74.2%(115명)가 수정 필요 비율을 20% 미만으로 평가하였으며, 수정이 필요하다고 응답한 집단(25.8%, 40명)의 보정 영역을 살펴보면, 주요 수정 작업은 대화 텍스트의 맥락 조정, 캐릭터 표정 이미지의 세부 표현, 분기 선택지 문구 수정에 집중되었다. 배경 이미지 전면 재생성이나 서사 구조 전체 재작성이 필요하다는 응답은 극소수에 그쳐, 시스템 산출 결과물의 기본 구조적 완성도는 전반적으로 수용 가능한 수준임을 시사한다. 그림 2에 제시된 실제 생성 결과물에서 확인할 수 있듯이, 동일 프로젝트 내 다수 장면에서 캐릭터 외형 정체성이 안정적으로 유지되었으며 배경과 캐릭터 간 시각적 일관성도 실무 적용 가능한 수준으로 확보되었다. 다만 감정 표현 변화 장면에서 미세한 외형 편차가 간헐적으로 관찰되었으며, 이는 페르소나 앵커 강도 정밀화를 통해 개선이 필요한 부분이다.

표 4. 생성 결과물 수정 필요 비율 분포(N=155)

Table 4. Distribution of required modification rate for generated outputs (N=155)

| Modification Rate | n | % |
|----------------------|-----|-------|
| 0% (No modification) | 15 | 9.7 |
| < 20% (Minor) | 100 | 64.5 |
| ~50% (Moderate) | 34 | 21.9 |
| ≥ 80% (Major) | 4 | 2.6 |
| Total | 155 | 100.0 |

표 5. 사용자 인상 응답 기반 결과물 품질 관련 언급 영역 분포(Q42, 복수 해당)

Table 5. Distribution of output quality-related mentions by users (Q42, multiple applicable)

| Quality Domain | Mentions (n) | % of Respondents |
|--------------------------------|--------------|------------------|
| Text / Dialogue / Scenario | 50 | 32.3 |
| Image / Character / Background | 44 | 28.4 |
| Branch Logic / Story Structure | 40 | 25.8 |
| Overall Completeness | 7 | 4.5 |

생성 결과물의 수정 필요 비율 분포를 살펴보면(표 4), 수정이 불필요하거나 20% 미만의 경미한 수정만 필요하다고 응답한 비율이 전체의 74.2%(115명)에 달하였으며, 대폭 수정(80% 이상)이 필요하다는 응답은 2.6%(4명)에 불과하였다. 사용자의 인상 깊은 기능 관련 주관식 응답(Q42)을 결과

물 품질 관련 언급 기준으로 분류한 결과(표 5), 텍스트·대사·시나리오 영역이 50명(32.3%)으로 가장 높은 언급 비율을 보였으며, 이미지·캐릭터·배경 44명(28.4%), 분기 로직·서사 구조 40명(25.8%) 순으로 나타났다. 이는 사용자들이 시스템의 통합 생성 능력을 다양한 품질 영역에 걸쳐 긍정적으로 인식하고 있음을 시사한다. 다만 본 분석은 주관식 응답의 키워드 빈도에 기반한 탐색적 분류로, 향후 블라인드 전문가 평가를 통한 객관적 품질 검증이 보완되어야 할 것이다. 제작 시간과 결과물 품질이 함께 개선된다는 점은 AI 통합 도구가 단순한 속도 향상 수단을 넘어 워크플로우 전반의 질을 높이는 데 기여함을 보여주는 실증적 근거로서 의미를 지닌다. 다만 기존 방식의 표준편차(SD=1434.0)가 극히 크다는 점은 응답자별 경험 수준과 인식 편차가 크게 반영된 결과로, 향후 동일 조건 통제 실험을 통한 객관적 비교 검증이 요구된다.

생성 결과물의 품질과 관련하여, 본 연구 시리즈의 선행연구에서 게임 업계 17년 경력 전문가에 의한 휴리스틱 평가가 수행되었으며, VN-AI Studio는 서사 흐름 일관성, 캐릭터 시각 일관성, 서사 분기 논리, 제작 효율성, 과물 수정 용이성의 5개 항목에서 종합 20/25점을 획득하였다. 이는 본 연구에서 응답자의 74.2%가 수정 필요성을 20% 미만으로 평가한 결과와 함께, 시스템이 산출하는 결과물이 실무 적용 가능한 수준의 품질을 갖추고 있음을 복합적으로 시사한다. 다만 사용자 주관 인식 기반 평가의 한계를 인정하며, 향후 연구에서 블라인드 전문가 평가를 통한 객관적 품질 검증이 요구된다.

표 6. 제작 소요 시간 인식 비교: 기존 방식 vs. VN-AI Studio
Table 6. Comparison of production time perception: Conventional vs. VN-AI Studio

| Condition | M (min) | SD | n |
|--------------------------------|---------|--------|-----|
| Conventional (Estimated) | 994.3 | 1434.0 | 154 |
| VN-AI Studio (Actual) | 4.6 | 3.1 | 154 |
| Paired Difference (Δ) | 989.7 | — | — |
| Perceived Time Change Rate | 97.7% | — | — |
| t (df = 153) | 8.565 | — | — |
| p-value | < .001 | — | — |
| Cohen's d | 0.690 | — | — |




그림 3. 생성 시간 분포 비교(왼쪽: 기존 추정치; 오른쪽: VN-AI 스튜디오 실제)
Fig. 3. Comparison of production time distribution (Left: Conventional estimated; Right: VN-AI Studio actual)

4-2 생산성 인식이 재사용 의향에 미치는 영향

구인별 기술통계 결과, 교육적 유용성(M=5.80), 창의성 지원(M=5.74), 제작속도 인식(M=5.71) 순으로 높게 평가된 반면, 인지 부하는 M=2.61로 7점 척도의 중위값(4점)을 크게 하회하였다. 이는 VN-AI Studio의 자연어 기반 인터페이스 설계가 사용자의 인지적 부담을 효과적으로 억제하고 있음을 나타낸다. 재사용 의향에 대한 단순회귀분석 결과, 생산성 인식이 재사용 의향 변량의 39.9%를 설명하는 가장 강력한 예측 변수로 나타났으며($\beta=0.677, R^2=.399, p<.001$), 사용 용이성($\beta=0.522, R^2=.241, p<.001$), 제작속도 인식($\beta=0.318, R^2=.199, p<.001$) 순으로 유의한 영향력이 확인되었다. 네 예측 변수 모두 통계적으로 유의한 영향을 보여 본 연구의 핵심 가설을 지지하였다. 표 7은 네 예측 변수의 단순 회귀 경로를 요약하여 제시한다.

이는 단순한 속도 향상보다 전반적인 생산성 개선 경험도 구의 지속 사용 의향을 결정하는 핵심 요인임을 보여준다. 특히 생산성 인식의 설명력($R^2=.399$)이 사용 용이성($R^2=.241$)보다 유의하게 높다는 점은, 사용자가 도구를 평가하는 기준이 인터페이스의 조작 편의성보다 실질적 생산성 향상 경험에 있음을 시사한다. 이는 기술 수용 모델(TAM)에서 지각된 유용성(Perceived Usefulness)이 지각된 용이성(Perceived Ease of Use)보다 채택 의향에 더 강한 영향을 미친다는 기존 연구 결과와 일치하는 방향이며[9], AI 통합 저작 도구의 설계에서 사용 편의성만큼 실질적 생산성 향상을 체감할 수 있는 경험 설계가 중요함을 함의한다. AI 도구의 초기 도입 전략에 있어서도 인터페이스 단순화와 함께 생산성 향상 효과를 사용자가 명확히 인식할 수 있도록 하는 온보딩 설계가 병행되어야 할 것이다.

표 7. 재사용 의도 예측을 위한 단순 회귀분석 결과

Table 7. Simple regression results predicting reuse intention

| Predictor → Reuse Intention | β | R^2 | t | p |
|-----------------------------|---------|-------|-------|--------|
| Productivity Perception | 0.677 | .399 | 13.47 | < .001 |
| Ease of Use | 0.522 | .241 | 9.98 | < .001 |
| Production Speed Perception | 0.318 | .199 | 8.46 | < .001 |
| Cognitive Load (-) | -0.291 | .195 | -6.64 | < .001 |

4-3 인지 부하와 도입 저항

인지 부하 세 문항의 문항별 평균은 Q34(프롭트 구성에 따른 피로감) M=2.63, Q35(생성 결과 검토 및 수정의 번거로움) M=2.53, Q36(집중력 및 노력 요구 수준) M=2.66으로, 세 문항 모두 7점 척도의 중위값(4점)을 크게 하회하였다. 신뢰도 계수($\alpha=.848$)가 높아 세 문항이 동일한 인지 부하 개념을 안정적으로 측정하고 있음도 확인되었다. 인지 부하가 재사용 의향에 미치는 영향을 분석한 결과, 유의한 부적 관계

가 나타났으며($\beta=-0.291, R^2=.195, p<.001$), 인지 부하가 낮을수록 도구의 지속 사용 의향이 높아지는 구조가 실증되었다. 이는 초기 학습 비용과 사용 과정에서 발생하는 정신적 부담이 도구 도입 저항의 주요 요인임을 보여주는 결과로서, 저작 도구 설계에서 인지 부하 완화 전략이 핵심 과제임을 구체적으로 함의한다.

현재 VN-AI Studio의 인지 부하 수준이 낮게 측정된 배경에는 자연어 기반 입력 인터페이스와 단일 파이프라인 설계가 핵심적으로 작용한 것으로 판단된다. 사용자가 복잡한 엔진 문법이나 에셋 관리 절차 없이 자연어 프롬프트만으로 전체 공정을 처리할 수 있는 구조는 인지적 전환 비용(Cognitive Switching Cost)을 최소화하며, 이는 도구의 반복 사용 의향을 높이는 데 실질적으로 기여한다. 그러나 인지 부하의 설명력($R^2=.195$)이 생산성 인식($R^2=.399$)에 비해 낮다는 점은, 인지 부하 감소 자체가 재사용 의향을 높이는 충분조건은 아님을 시사한다. 도구 설계에서 인지 부하 완화와 생산성 향상 경험을 동시에 달성하는 통합적 접근이 필요하며, 특히 초기 사용 단계에서의 온보딩 최적화가 도입 저항을 낮추는 핵심 전략이 될 수 있다.

4-4 개발 경험 수준에 따른 효율 인식 동질성

게임 개발 경험 수준을 4집단(경험 없음, 1년 미만, 1~3년, 3년 이상)으로 구분하여 제작 효율 인식(Q6)의 집단 간 차이를 일원분산분석으로 검증한 결과, 집단 간 유의한 차이가 나타나지 않았다($F=0.276, df=3/151, p=.843, \eta^2=.006$). 경험 없음 집단($M=5.70, SD=0.95$)부터 3년 이상 전문가 집단($M=5.67, SD=1.18$)까지 평균 차이는 최대 0.22에 불과하여, 사실상 동등한 수준의 효율 인식을 보였다. Tukey HSD 사후검정에서도 어떠한 집단 쌍에서도 유의한 차이가 확인되지 않았다. 이는 AI 통합 저작 도구의 효율 인식이 게임 개발 경력과 무관하게 안정적으로 형성됨을 의미하며, 표 8 및 그림 4는 집단별 제작 효율 인식 분포와 AI 역할 인식 분포를 각각 제시한다. 본 결과는 AI 통합 저작 도구가 게임 개발의 기술 격차를 해소하고 창작을 민주화함을 시사한다. 비전문가도 전문가 수준의 도구 효율을 체감한다는 점에서, AI-Native Pipeline은 다양한 역량의 창작자를 아우르는 범용적 환경임을 실증하며 전문 기술이 없는 학습자에게도 완성도 높은 제작 경험을 제공하여, 교육 현장 도입의 강력한 근거가 될 수 있다.

표 8. 개발 경험 수준에 따른 제작 속도 인식의 일원분산분석

Table 8. One-Way ANOVA: Production speed perception by development experience level

| Experience Level | n | M | SD | F | p |
|------------------|-----|------|------|-------|------|
| None | 11 | 5.70 | 0.95 | 0.276 | .843 |
| < 1 year | 33 | 5.58 | 1.32 | | |
| 1-3 years | 65 | 5.80 | 1.12 | | |
| 3+ years | 45 | 5.67 | 1.18 | | |
| Total | 155 | 5.71 | 1.20 | | |




그림 4. 개발 경험 수준에 따른 제작 속도 인식의 일원분산분석
Fig. 4. Distribution of perceived role of AI in the creative workflow (N = 154)

V. 산업적 시사점

5-1 공정 단축과 조직 생산성 향상 가능성

본 연구에서 확인된 97.7%의 제작 시간 단축은 단순한 작업 속도 향상을 넘어 게임 개발 조직의 프로토타이핑 사이클 전체를 재정의하는 의미를 갖는다. 기존 방식에서 수 시간에서 수일이 소요되던 시안 제작이 분 단위로 압축됨으로써, 단일 작업 세션 내에서 복수의 시나리오 방향을 비교·검토하는 반복적 탐색 기획이 가능해진다. 기존에는 리소스 제약으로 인해 소수의 방향성만 탐색할 수밖에 없었던 상황에서, AI 통합 파이프라인은 다양한 방향성을 빠르게 시험하고 최적안을 선별하는 ‘다작 후 선택(Generate-then-Select)’ 워크플로우를 현실적인 선택지로 만든다. 이는 게임 기획 단계에서의 창의적 다양성 확보와 결과물 품질 향상 모두에 기여하는 이중 효과를 가진다. 또한 74.2%의 응답자가 생성 결과물의 수정 필요성을 20% 미만으로 평가한 결과는, AI 통합 파이프라인이 단순한 초안 생성 도구를 넘어 즉시 활용 가능한 제작물을 산출할 수 있는 수준에 도달했음을 시사한다. 특히 소규모 인디 스튜디오나 1인 창작자 환경에서는 AI 통합 파이프라인이 팀 규모의 한계를 극복하는 핵심 수단으로 기능할 수 있으며, 퍼블리셔 없이도 경쟁력 있는 콘텐츠를 독립적으로 제작·출시하는 환경 가능성을 탐색적으로 시사한다. 이 같은 결과는 대형 스튜디오뿐 아니라 1인 창작자에 이르기까지 다양한 규모의 제작 주체가 AI 통합 도구를 중심으로 콘텐츠 생산 역량을 재구성하는 방향으로 산업 구조 변화 방향과 부합하는 탐색적 근거를 제공한다.

5-2 소규모 팀·1인 개발 환경 확장 가능성

교육적 유용성($M=5.80$)이 가장 높게 평가된 점과 개발 경험 무관하게 효율 인식이 동질적으로 나타난 점은 AI 통합 저

작 도구가 전문 인력 의존도를 구조적으로 낮출 수 있음을 시사한다. 코딩이나 아트 역량 없이 기획 의도만으로 프로토타입이 가능한 환경은 1인 개발자 및 교육 현장의 게임 제작 저변 확대에 기여한다. Ren·Py 문법 습득이나 아트 제작 기술이라는 진입 장벽이 낮아져 학습자는 서사 설계와 게임플레이 구조 탐구에 더 일찍 집중할 수 있다. 웹툰·소설 작가 등 서사 기획 역량을 갖춘 비전문가들도 기술적 장벽 없이 인터랙티브 콘텐츠를 제작할 수 있어 게임 산업의 콘텐츠 공급 저변이 확장된다. 게임 전공 교육에서 기술 학습과 창작 기획 간의 균형을 재설정하는 기회가 될 수 있다. AI 통합 도구로 학습자는 엔진 코딩 숙련도 이전에도 완성도 높은 프로토타입을 경험하며, 분기 서사·캐릭터 개성·인터랙션 설계에 대한 직관적 이해를 빠르게 형성 가능하다. 팀 단위 프로젝트에서도 역할 분담 방식이 변화한다. 기존엔 기획·아트·프로그래밍 역할이 엄격히 분리되었으나, AI-Native Pipeline 환경에서는 기획자가 전체 프로토타입 제작을 주도하고 다른 팀원은 창의적 검토·개선에 집중하는 방식으로 재편될 수 있다.

5-3 AI 기반 공정 재설계 전략

응답자의 37.0%(57명)가 AI를 동료·파트너로, 33.5%(52명)가 조수·어시스턴트로 인식한 결과는 사용자가 이미 AI를 단순 도구가 아닌 협업 주체로 수용하고 있음을 보여준다. 반면 단순 도구로 인식한 응답자는 21.0%(32명)에 불과하였으며, AI를 멘토로 인식하는 경우도 8.4%(13명) 존재하였다. 이러한 AI 인식 방식의 분포는 사용자의 관점이 수동적 명령 수행 도구에서 능동적 협업 프레임으로 전환되고 있음을 시사하며, 향후 저작 도구 설계 방향에 중요한 함의를 제공한다. 특히 사용자가 AI를 협업 주체로 인식하는 환경에서는 단순 명령어 실행 중심의 인터페이스보다 창작 의도를 능동적으로 보완하고 제안하는 협업 지향 인터페이스 설계가 더 높은 만족도와 생산성을 이끌어낼 가능성이 높다고 판단된다.

5-4 게임 산업에서 AI-Native Pipeline의 의미

본 연구의 결과는 AI 통합 저작 도구가 개별 도구의 단순 조합인 Tool Adoption을 넘어, 제작 공정의 구조적 병목을 제거하는 Process Re-engineering으로서 기능할 수 있음을 실증적으로 지지한다. 자연어 입력에서 실행 가능한 빌드까지 단절 없이 연결되는 AI-Native Pipeline은 진입 장벽 해소, 제작 사이클 압축, 비전문가 접근성 확대라는 세 가지 측면에서 게임 산업의 제작 패러다임 전환 방향과 부합하는 핵심 인프라로 기능할 수 있는 초기 근거를 제공한다[7]. 모바일 게임 시장 확대와 단단 인터랙티브 콘텐츠 수요 증가를 고려할 때, AI-Native Pipeline의 효율성은 시장 반응 속도와 콘텐츠 다양성 측면에서 중요한 경쟁 우위를 제공한다. 장기적으로는 멀티 에이전트 시스템과 결합해 서사 생성, 에셋

제작, 사운드 생성, QA 검증 단계를 독립적 AI 에이전트가 병렬로 처리하는 구조로 발전할 수 있으며, 이는 제작 품질과 속도를 동시에 향상시킨다. 본 연구는 이러한 발전 방향에 대한 실증적 기반과 사용자 인식 구조 분석을 통해 설계 방향성에 대한 시사점을 제시한다. 향후 BGM·효과음 생성 모듈까지 포함하는 통합 멀티모달 저작 환경으로의 고도화는 AI-Native Pipeline 완성도를 높이는 핵심 연구 방향이며, 게임 제작 전 영역에서 AI-Native 환경 실현 가능성을 확인하는 것이 향후 과제다.

VI. 결 론

6-1 연구 요약

본 연구는 AI 기반 통합 저작 도구 VN-AI Studio를 대상으로 실제 사용자(N=155)의 제작 효율 인식 구조와 재채택 결정 요인을 실증적으로 분석하였다. 주요 결과는 세 가지로 요약된다. 첫째, 기존 방식 대비 평균 97.7%의 제작 시간 단축이 통계적으로 유의하게 확인되었으며($t=8.565, p<.001, Cohen's d=0.690$), 응답자의 74.2%가 생성 결과물의 수정 필요성을 20% 미만으로 평가하였다. 이는 AI 통합 파이프라인이 물리적 시간 압축과 결과물 품질의 실용적 수용 가능성을 동시에 달성하고 있음을 의미한다. 둘째, 생산성 인식이 재사용 의향의 39.9%를 설명하는 핵심 예측 변수로 나타났으며($\beta=0.677, p<.001$), 인지 부하는 재사용 의향에 유의한 음의 영향을 미치는 것으로 나타났다($\beta=-0.291, p<.001$).

셋째, 게임 개발 경험 수준과 무관하게 제작 효율 인식이 동질적으로 나타나($F=0.276, p=.843$), AI 통합 저작 도구가 기술 역량 격차를 완화하고 비전문가 환경으로의 확장 가능성을 실증적으로 지지함이 확인되었다. 이러한 결과들은 VN-AI Studio가 단순한 생산성 향상 도구를 넘어, 게임 제작의 구조적 패러다임을 전환하는 AI-Native Pipeline으로서의 역할을 수행할 수 있음을 시사한다. 특히 비전문가와 전문가가 집단 모두에서 일관되게 높은 효율 인식이 나타난 점은, AI 통합 저작 도구가 사용자 계층을 막론하고 범용적인 제작 효율화 수단으로 자리할 수 있는 가능성을 실증적으로 보여준다.

6-2 한계 및 향후 연구 방향

본 연구는 다음과 같은 한계를 가진다. 첫째, 일부 구인의 신뢰도 계수(α)가 기준치에 미달하여 측정 도구의 타당성 보완이 필요하다. 생산성 인식($\alpha=.474$)과 재사용 의향($\alpha=.585$)의 경우 문항 구성을 재검토하고 확인적 요인분석을 통해 구인 타당도를 추가 검증할 필요가 있다. 둘째, 단일 저작 도구를 대상으로 한 연구로서 결과의 일반화에 한계가 있으며, 유

사한 다른 AI 통합 도구들과의 비교 연구가 이루어지지 않아 도구 특성 효과와 AI 통합 효과를 분리하여 해석하기 어렵다. 셋째, 단일 시점의 횡단 데이터를 활용하였으므로 장기적 사용 행태 변화와 숙련도 축적에 따른 인식 변화를 추적한 종단 연구가 부재하며, 단기 사용 경험이 장기적 채택 행동으로 이어지는지에 대한 추가 검증이 요구된다. 넷째, 기존 방식 제작 시간은 응답자의 주관적 예상치를 기반으로 하며 VN-AI Studio 실제 측정치와 측정 조건이 상이하다. 향후 연구에서는 동일 과제·동일 환경의 통제 실험 설계를 통해 보다 엄밀한 비교 검증이 이루어져야 할 것이다. 향후 연구에서는 정제된 측정 도구를 활용한 대규모 검증과 함께, 멀티 에이전트 시스템 기반의 파이프라인 확장 및 RPG, 로그라이크 등 상호작용성이 높은 타 장르로의 적용 가능성을 검토해야 할 것이다. 또한 생성형 AI의 멀티모달 역량 확장에 따른 BGM·효과음·모션 통합 저작 환경으로의 고도화와 함께, 대규모 사용자 집단을 대상으로 한 A/B 테스트 기반의 인터페이스 최적화 연구가 중요한 후속 과제로 남는다. 본 연구에서 확인된 AI 역할 인식 유형(동료/조수/도구/멘토)이 생산성 인식 및 재사용 의향에 미치는 조절 효과 분석도 AI 도구 사용자 행동 연구에 풍부한 이론적 기여를 제공할 것으로 기대된다.

감사의 글

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 메타버스 융합대학원의 연구 결과로 수행되었음(RS-2022-00156318).

본 연구는 서울시 산학연 협력사업(Seoul R&BD Program)의 지원을 받아 수행되었음(CC250064, CY250171).

참고문헌

[1] J. Camingue, E. Carstensdottir, and E. F. Melcer, "What Is a Visual Novel?," *Proceedings of the ACM on Human-Computer Interaction*, Vol. 5, 285, October 2021. <https://doi.org/10.1145/3474712>

[2] Y. Han, H. Lee, and Y. Kim, "Ensemble Engine: Framework Design for Visual Novel Game Production," *Journal of the Korean Society of Computer and Information*, Vol. 24, No. 3, pp. 25-33, 2019.

[3] S. Shields, A. Calderwood, S. Johnson-Bey, N. Wardrip-Fruin, M. Mateas, and E. Melcer, "Generating Together: Lessons Learned from Developing an Educational Visual Novel with AI Collaboration," in *Proceeding of the IEEE Conference on Games (CoG)*, Milan, Italy, pp. 1-8, 2024. <https://doi.org/10.1109/CoG60054.2024.10645553>

[4] A. Begemann and J. Hutson, "Empirical Insights into AI-Assisted Game Development: A Case Study on the Integration of Generative AI Tools in Creative Pipelines," *Metaverse*, Vol. 5, No. 2, pp. 2568-2585, 2024. <https://doi.org/10.54517/m.v5i2.2568>

[5] Y. Bole, "Integrating Generative AI into Game Development Pipelines: A User-Centered Approach to Creative Efficiency," *Information Systems Student Research Journal (ISSRJ)*, Vol. 2, No. 1, pp. 45-62, 2025.

[6] S. Xia, "Generative AI in Game Development: A Bibliometric Study with an Auditable Computing Workflow" in *Proceedings of the 2025 International Conference on Artificial Intelligence, Virtual Reality and Interaction Design*, New York, NY, pp. 700-714, 2025.

[7] D. H. Husen and W. Istiono, "Procedural Story Generation for Visual Novels Using Large Language Models and Text-to-Image," *Journal of Games Art, and Gamification*, Vol. 10, No. 3, pp. 106-114, 2025.

[8] Grid Dynamics Team. Game Assets Creation with Generative AI Tools: A Tutorial [Internet]. Available: <https://www.griddynamics.com/blog/game-asset-creation-with-generative-ai>.

[9] H. Lee, "Analysis of the Use of AI-Generated Content (AIGC) in Game Narrative Design," *Journal of the Korean Game Society*, Vol. 24, No. 4, pp. 55-68, 2024.

[10] A. Kim, "Study of Production Workflows in Interactive 3D Animation with AI Tools," *Journal of the Korean Digital Contents Society*, Vol. 25, No. 12, pp. 3177-3184, 2024.

[11] S. A. Alharthi, "Generative AI in Game Design: Enhancing Creativity or Constraining Innovation?," *Journal of Intelligence*, Vol. 13, No. 6, 60, 2025.



김태완(Taewan Kim)

2002년 : 부산대학교 예술대학 미술학과

2017년 : 가천대학교

게임대학원(게임학 석사)

2024년~현재 : 서강대학교 가상융합전문대학원 테크놀로지 전공 박사과정

※ 관심분야 : 생성형 인공지능(Generative AI), 게임 콘텐츠 개발 자동화(Game Content Automation), 오픈 소스 인공지능 모델 응용(Application of Open-source AI Models)



김태훈(Taehoon Kim)

2018년 : 서강대학교 (공학사 & 문학사, 컴퓨터공학 & 신문방송학)

2021년 : 서강대학교 대학원 (공학박사, 컴퓨터공학)

2021년~2024년: LG AI 연구원

2024년~현 재: 서강대학교 가상융합전문대학원 조교수

※관심분야 : 멀티모달 인공지능(Multimodal AI), 컴퓨터비전 (Computer Vision), 생성형 인공지능(Generative AI)