

비주얼 노벨 창작자 유형 분류 및 LLM 기반 적응형 내러티브 분기 생성 파이프라인 연구

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

A Study on Creator-Type Classification and LLM-Based Adaptive Narrative Branch Generation Pipeline for Visual Novels

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]

생성형 AI 기반 비주얼 노벨 저작 환경에서 사용자는 AI를 서로 다른 방식으로 인식하고 활용한다. 본 연구는 VN-AI Studio 사용자(N=145) 설문 데이터를 기반으로 AI 역할 인식 유형에 따라 창작자를 Co-Creator, Director, Craftsman, Learner의 4 유형으로 분류하고, 유형-직무 간 분포의 통계적 유의성을 확인하였다($\chi^2=35.38$, $p<.001$). 또한 각 유형의 특성을 LLM 프롬프트 파라미터에 매핑하는 적응형 내러티브 분기 생성 파이프라인을 제안하였으며, 개념 검증(PoC) 실험을 통해 동일 프롤로그에서 유형별로 의미론적으로 차별화된 분기 내러티브가 생성됨을 코사인 유사도 분석으로 검증하였다(평균 유사도 0.31). 본 연구는 사용자 유형 다양성을 고려한 개인화 내러티브 생성 파이프라인을 제안함으로써, AI 기반 게임 저작 연구에 새로운 설계 관점을 제시하고 멀티 에이전트 기반 동적 개인화 시스템으로의 확장을 위한 이론적·실증적 기반을 마련한다.

[Abstract]

In AI-assisted visual novel authoring environments, users perceive and interact with AI in fundamentally different ways. This study analyzes survey data collected from VN-AI Studio users (N=145) to classify creators into four types — Co-Creator, Director, Craftsman, and Learner — based on their AI role perception. These results confirm statistically significant differences in creator-type distribution across job categories ($\chi^2=35.38$, $p<.001$). This study proposes an adaptive narrative branch generation pipeline that maps the characteristics of each creator type to large language model (LLM) prompt parameters. A proof-of-concept (PoC) experiment demonstrates that semantically differentiated narrative branches can be generated from the same prologue when different type parameters are applied. The differentiation was further validated through cosine similarity analysis (mean similarity = 0.31). The proposed framework introduces a user-type-aware personalized narrative generation pipeline and offers a novel design perspective for AI-driven game authoring research. Furthermore, the study establishes both a theoretical and empirical foundation for future extensions toward multi-agent-based dynamic personalization systems.

색인어 : 비주얼 노벨, 생성형 AI, 대규모 언어 모델, 창작자 유형, 적응형 내러티브**Keyword** : Visual Novel, Generative AI, LLM, Creator Type, Adaptive Narrative<http://dx.doi.org/10.9728/dcs.2026.27.6.1619>

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 16 April 2026

Accepted 04 May 2026

***Corresponding Author; Taehoon Kim**

Tel: +82-2-705-8902

E-mail: taehoonkim@sogang.ac.kr

I. 서 론

1-1 연구 배경 및 필요성

비주얼 노벨 제작은 기획·아트·스크립트·빌드의 다단계 공정으로 분절되어 높은 시간 비용과 진입 장벽을 형성하며, 이러한 구조적 문제는 소규모 팀과 1인 개발 환경에서 특히 심각하게 나타난다[1]. 최근 생성형 AI 기반 통합 저작 도구가 이러한 공정 분절 문제를 해소하는 데 유효하다는 사실이 실증되었으나[1], 사용자마다 AI를 인식하고 활용하는 방식이 상이하다는 점은 아직 충분히 규명되지 않았다. 최근 대규모 언어 모델(LLM: Large Language Model)의 제작 공정의 자동화 가능성을 열었으나, 현재의 범용AI 도구 활용 방식은 도구 간 통합 없이 텍스트와 이미지를 단편적으로 생성하는 수준에 머물러 있다[2].

기존 연구들은 LLM 기반 저작 도구가 제작 효율을 향상시킨다는 사실을 보여주었으나, 그 효과가 모든 사용자에게 동일하게 나타나지 않는다는 점에 주목할 필요가 있다. 사용자마다 AI를 활용하는 방식, 창작 과정에서의 역할 인식, 그리고 원하는 내러티브 경험이 상이하기 때문이다[3]. 본 연구는 이러한 문제의식에서 출발하여, AI 기반 비주얼 노벨 저작 환경에서 나타나는 창작자 유형을 분류하고, 각 유형의 특성에 맞는 적응형 내러티브 분기 생성 파이프라인을 제안하고자 한다.

1-2 연구 목적 및 기여

본 연구의 목적은 세 가지로 정리된다. 첫째, 생성형 AI 기반 비주얼 노벨 저작 시스템(VN-AI Studio) 사용자 설문 데이터(N=145)를 기반으로 AI 인식 유형에 따른 창작자 프로파일을 도출한다. 둘째, 도출된 유형별 특성을 LLM 프롬프트 파라미터에 매핑하는 적응형 내러티브 생성 파이프라인을 설계한다. 셋째, 동일한 프로로그에서 유형별로 상이한 분기 내러티브가 생성됨을 개념 검증(PoC)을 통해 시연하고, 코사인 유사도 분석으로 분기 차별성을 정량 검증한다.

본 연구의 기여는 다음과 같다. 기존 연구가 AI 저작 도구의 평균적 효용에 집중했다면, 본 연구는 사용자 유형 다양성을 고려한 개인화 관점을 도입한다는 점에서 차별화된다. 또한 선행 연구에서 제안된 VN-AI Studio 시스템을 기반으로 유형-프롬프트 매핑 구조를 확장함으로써, AI-Native 게임 제작 파이프라인 연구의 실용적 후속 연구로서의 위치를 갖는다. 나아가 N=145의 실증 데이터를 기반으로 유형 간 직무 분포의 통계적 유의성을 검증($\chi^2=35.38$, $p<.001$)함으로써 이론적 근거를 강화한다.

II. 관련 연구

2-1 플레이어 유형론과 AI 적응형 내러티브

플레이어 유형론의 가장 널리 알려진 프레임워크는 Bartle 이 제안한 MUD 플레이어 분류로, 성취자(Achiever), 탐험가(Explorer), 사교가(Socializer), 킬러(Killer)의 4유형을 행동 경향에 따라 구분하였다[4]. 이후 Yee는 이 분류를 확장하여 성취, 사회, 몰입의 3차원 동기 모델을 제시하였으며, 게임 유형에 따라 플레이어 동기 구조가 달라짐을 밝혔다[5]. 비주얼 노벨 맥락에서는 서사 선택 행동과 분기 탐색 성향이 플레이어 유형을 구분하는 핵심 변수로 작용하며, 이는 적응형 내러티브 설계의 이론적 기반이 된다. 최근 AI기반 게임 콘텐츠 연구에서는 플레이어 특성에 따른 콘텐츠 개인화가 주요 관심사로 부상하고 있다. Taveekitworachai 외는 LLM을 활용한 스토리 분기 생성 시스템을 제안하며 플레이어 선택에 따른 서사 다양성 확보 가능성을 시연하였다[6]. Kumaran 외는 SceneCraft 시스템을 통해 LLM이 게임 내 장면을 자동으로 생성하고 분기를 관리할 수 있음을 보였다[7]. 그러나 이들 연구는 플레이어의 개인적 창작 성향이나 AI 인식 방식을 반영한 개인화 파이프라인을 다루지 않았다는 한계가 있다.

2-2 LLM 기반 비주얼 노벨 저작 도구

LLM 기반 비주얼 노벨 저작 도구 분야에서는 VN-AI Studio가 기승전결 4단계 클러스터링 구조와 페르소나 앵커 기법을 통해 서사 생성 자동화 및 캐릭터 시각 일관성 문제를 해결한 사례로 주목된다. 본 연구는 이 시스템을 기반 플랫폼으로 삼아, 여기에 사용자 유형 적응 레이어를 추가하는 방식으로 연구를 확장한다. Bhandari 외는 LLM 에이전트의 페르소나 일관성 유지 능력을 검증하며, 적절한 프롬프트 설계가 캐릭터 스타일의 일관성을 96% 이상 유지할 수 있음을 보였다[8].

Big Five (OCEAN) 성격 모델을 LLM 기반 캐릭터 생성에 적용한 연구는 추상적인 성격 파라미터가 실제 언어 출력에 정량적으로 반영됨을 실증하였다. 특히 개방성(Openness)과 어휘 다양성(TTR: Type-Token Ratio)간의 강한 상관관계($r=0.71$)는 심리학적 특성 수치가 LLM 프롬프트 제어 변수로 유효하게 기능함을 시사한다[9]. 본 연구는 이 접근을 창작자 유형 특성으로 확장하여, 유형별 서사 스타일 선호를 프롬프트 파라미터로 매핑하는 근거로 활용한다.

2-3 생성형 AI 도구의 사용자 경험 연구

생성형 AI 도구의 사용자 경험 연구에서 기술수용모델

(TAM)은 지각된 유용성과 사용 용이성이 실제 사용 의도를 예측하는 핵심 변수임을 반복적으로 확인해 왔다[10]. 최근 연구들은 여기에 창의성 지원, 인지 부하, 통제감 등의 변수를 추가한 확장 TAM을 적용하는 경향이 있다. 본 연구의 설문 데이터는 생산성 인식, 사용 용이성, 창의성 지원, 인지 부하, 재사용 의향의 5개 척도를 포함하며, 이를 유형별로 비교 분석함으로써 유형-경험 간 관계를 탐색한다.

III. 창작자 유형 분류 분석

3-1 연구대상 및 설문 설계

본 연구의 데이터는 LLM 기반 비주얼 노벨 저작 시스템 ‘VN-AI Studio’를 직접 체험한 참여자를 대상으로 수집된 온라인 설문에 기반하며, 선행 연구[1]와 동일한 데이터셋을 활용하였음을 밝힌다. 표본의 수집 절차 및 인구통계학적 특성에 관한 상세 내용은 선행 연구[1]에 보고된 바와 같다. 동일 원데이터(N=173) 중 AI 역할 인식 항목(Q40) 무응답자를 추가 제거하여 최종 N=145를 본 연구의 분석 대상으로 확정하였다. 주된 직무 구성은 프로그래밍/엔지니어링 47명, 아트/디자인 44명, 게임 기획/시나리오 33명, 연구/학술 18명 순이었다. 본 연구는 선행 연구에서 측정된 제작 효율 인식 및 워크플로우 혁신 효과를 전제로, 동일 표본 내 AI 역할 인식 유형 분포와 직군별 차이 분석에 초점을 맞춘다.

3-2 AI 역할 인식 기반 4유형 도출

AI 인식 유형 분류 결과, Co-Creator(동료/파트너) 유형이 53명(36.6%)으로 가장 높은 비율을 차지하였으며, Director Assistant/Tool Operator 48명(33.1%), Craftsman(단순 도구) 31명(21.4%), Learner(멘토/선생님) 13명(9.0%) 순으로 나타났다. 특히 Co-Creator와 Director 유형을 합산하면 전체의 69.7%에 해당하여, 대다수의 사용자가 AI를 단순한 기능적 도구를 넘어 협력적 또는 보조적 파트너로 인식하고 있음을 확인할 수 있다. 이는 최근 생성형 AI 환경에서 나타나는 인간-AI 협업 패러다임의 확산을 반영하는 결과로 해석된다.

이러한 분포는 AI를 활용하는 사용자의 인식이 단순한 도구 사용에서 점차 상호작용적 관계로 확장되고 있음을 시사하며, 특히 창작 맥락에서는 AI를 ‘공동 창작자(co-creator)’ 또는 ‘지시를 수행하는 보조자(director assistant)’로 받아들이는 경향이 강하게 나타난다. 이는 기존의 생산성 도구 중심 인터페이스에서 벗어나, AI를 사회적 행위자로 인지하는 경향과도 연결된다.

또한, 본 연구에서 도출된 네 가지 유형은 Bartle의 플레

어 유형론과 유사한 행동 경향 구조를 보이며, 각각 고유한 상호작용 스타일과 목표 지향성을 가진다. Co-Creator 유형은 아이디어 생성 및 확장 과정에서 AI와의 협력적 상호작용을 선호하며, 서사 공동 창작 과정에서 높은 참여도를 보인다. Director 유형은 명확한 의도와 목표를 기반으로 AI를 지시·통제하는 경향이 강하며, 결과물의 구조적 완성도를 중시한다. Craftsman 유형은 AI를 효율적인 기능 수행 도구로 활용하여 작업 속도와 생산성을 극대화하는 데 초점을 둔다. 반면 Learner 유형은 AI를 지식 습득 및 탐색의 매개체로 활용하며, 새로운 아이디어와 개념을 학습하는 과정 자체에 가치를 둔다.

이러한 유형 구분은 단순한 사용자 특성 분류를 넘어, AI 기반 콘텐츠 생성 시스템 설계에 있어 중요한 시사점을 제공한다. 즉, 동일한 시스템이라도 사용자 유형에 따라 인터페이스, 제어 방식, 생성 결과의 다양성 수준을 다르게 설계할 필요가 있으며, 특히 Co-Creator 및 Director 유형이 높은 비율을 차지한다는 점에서 협력적 상호작용과 제어 가능성을 동시에 지원하는 설계 전략이 요구된다.

표 1. AI 역할 인식을 기반으로 한 창작자 유형 분포(N=145)

Table 1. Creator type distribution based on AI Role perception (N=145)

Type	N	Ratio (%)	AI Role Perception
Co-Creator	53	36.6	Partner / Collaborator
Director	48	33.1	Assistant / Tool Operator
Craftsman	31	21.4	Simple Tool / Executor
Learner	13	9.0	Mentor / Guide
Total	145	100.0	-

Creator Type Distribution (N=145)




그림 1. AI 역할인식 창작자 유형 분포

Fig. 1. Distribution of creator types by AI role perception

직무 범주와 창작자 유형 간의 분포 차이를 확인하기 위해 카이제곱 독립성 검정을 실시하였다. 결과적으로 $\chi^2(12, N=145)=35.38, p<.001$ 수준에서 유의한 차이가 확인되었다 (Table 2). 세부 분포를 보면 엔지니어링 직군은 Director 유형(25명, 52.1%)이 가장 많았으며, 아트/디자인 직군은 Co-Creator 유형(20명, 45.5%)이 두드러졌다. 게임 기획 직군은 Co-Creator와 Director, Craftsman이 비교적 고르게 분포하였고, 연구/학술 직군은 Co-Creator 비율이 높게 나타났다. 이는 직무 특성에 따라 AI 협업 방식에 대한 인식이 체계적으로 다를 수 있음을 시사한다. 다만 창작자 유형 분류가 단일 설문 문항(Q40)에 의존한다는 방법론적 한계가 존재한다. Co-Creator와 Director처럼 능동적 AI 활용 성향을 공유하는 유형 간 경계는 행동 수준에서 중첩될 수 있으며, 향후 다 문항 척도 또는 행동 로그 기반 분류를 통한 검증이 필요하다.

표 2. 직무 범주와 창작자 유형 간의 분포 차이

Table 2. Cross-tabulation of job category and creator type

Job	Co-C	Dir.	Craft.	Learn.	Total
Engineering	13	25	7	2	47
Art/Design	20	7	10	7	44
Planning	10	12	10	1	33
Research	10	4	3	1	18
Total	53	48	30	11	142

$\chi^2(12)=35.38, p<.001$




그림 2. 직무 범주별 창작자 유형 분포

Fig. 2. Creator type distribution by job category

IV. 유형별 적응형 내러티브 파이프라인 설계

4-1 파이프라인 구조 개요

제안 파이프라인은 그림3과 같이 입력 레이어, 유형 분류 레이어, 프롬프트 생성 레이어, 서사 출력 레이어의 4단계로 구성된다. 입력 레이어에서는 사용자의 초기 게임 테마와 설

정 정보를 자연어로 수집하고, 동시에 간단한 상호작용 패턴 (선택 속도, 수정 횟수, 프롬프트 길이 등) 또는 명시적 유형 선택을 통해 창작자 유형을 결정한다. 유형 분류 레이어는 실시간 로그 기반 규칙 분류와 사용자 자가 선택 두 가지 경로를 지원하며, 장기 사용 환경에서는 k-means 클러스터링을 통한 자동 유형 갱신도 가능하다.

프롬프트 생성 레이어에서는 확정된 창작자 유형을 기반으로 서사 생성 파라미터 집합(@_type)을 구성하여 LLM에 주입한다. 각 유형의 파라미터는 서사 밀도(Narrative Density), 분기 복잡도(Branch Complexity), 감정 강도(Emotional Intensity), 선택 자율성(Agency Level)의 4개 축으로 정의되며, 유형별 설정 값은 표 3과 같다. Co-Creator 유형은 감정 강도와 선택 자율성을 높게 설정하여 공동 창작 경험을 극대화하고, Director 유형은 서사 밀도와 분기 복잡도를 높여 정교한 구조 제어를 지원한다. Craftsman 유형은 단순 선행 구조와 낮은 감정 표현으로 기능 중심 경험을 제공하며, Learner 유형은 해설형 내러티브와 낮은 분기 복잡도로 학습 친화적 환경을 구성한다.

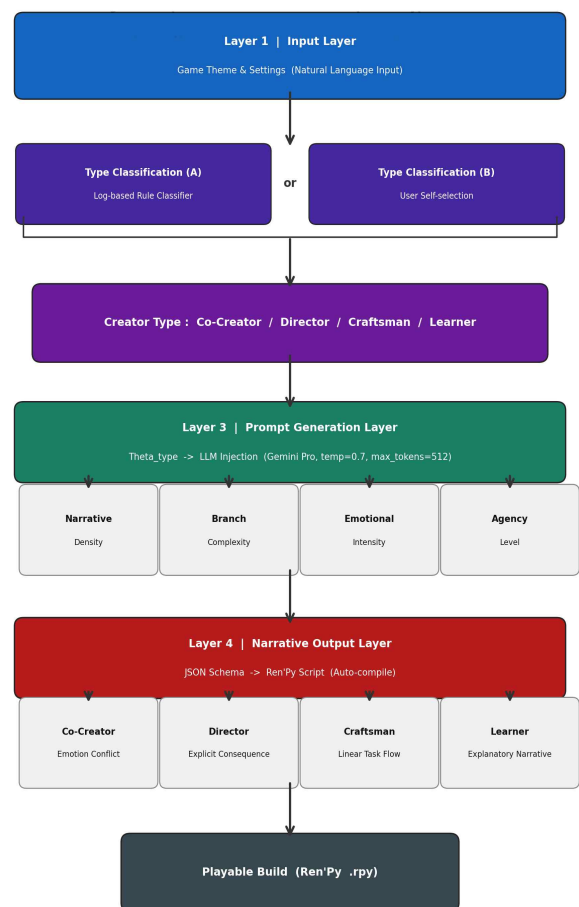


그림 3. 유형별 적응형 내러티브 파이프라인 구조

Fig. 3. Adaptive narrative generation pipeline architecture by creator type

표 3. 창작자 유형별 내러티브 생성 매개변수 맵핑

Table 3. Narrative generation parameter mapping by creator type

Type	Density	Branch Comp.	Emotion Intensity	Agency Level
Co-Creator	Med	Med	High	High
Director	High	High	Med	High
Craftsman	Low	Low	Low	Med
Learner	Med	Low	Med	Low

4-2 유형별 서사 제약 조건 설계

유형-프롬프트 매핑의 구체적 구현은 VN-AI Studio의 기(起)-승(承)-전(轉)-결(結) 기반 클러스터링 구조 위에 유형별 제약 레이어(Type-specific Constraint Layer)를 추가하는 방식으로 설계된다. 기존 시스템은 기승전결의 4단계 거시적 서사 구조를 고정하고, 각 단계별 장면 수 및 분기 조건을 사전에 정의된 규칙에 따라 제한함으로써 기본적인 서사 일관성을 확보하였다.

본 연구에서 제안하는 파이프라인은 이러한 거시 구조(Macro Structure)를 유지하면서, 사용자 유형에 따라 상이한 미시적 제약(Micro-Constraint)을 동적으로 주입하는 계층적 구조를 따른다. 즉, 동일한 서사 골격을 공유하되, 각 유형의 인지적·행동적 특성에 부합하는 서사 패턴을 생성하도록 제어하는 방식이다.

예를 들어, Co-Creator 유형의 경우 AI와의 협력적 상호작용을 선호하는 특성을 반영하여, 전(轉) 단계에서 감정적 갈등 또는 선택 기반 긴장 구조를 최소 2회 이상 포함하도록 강제함으로써 서사 참여도를 증대시킨다. 반면 Director 유형은 결과 중심적 의사결정 성향을 가지므로, 각 분기 지점마다 명시적인 결과(Consequence) 서술을 포함하도록 제약을 설정하여, 선택과 결과 간 인과 관계를 강화한다. Craftsman 유형의 경우 불필요한 서사 확장을 최소화하고 기능적 진행 흐름을 유지하는 방향으로 분기 수를 제한하며, Learner 유형은 설명적 내러티브 및 배경 정보 노출을 강화하는 방식으로 미시 제약이 적용된다.

이러한 유형별 제약은 프롬프트 수준에서의 조건 삽입뿐 아니라, 생성 결과에 대한 후처리(Post-processing) 단계에서도 이중으로 적용되어, 출력 품질과 일관성을 동시에 확보한다. 결과적으로 본 구조는 단순한 프롬프트 엔지니어링을 넘어, 서사 생성 규칙을 구조적으로 제어하는 파라미터화된 생성 시스템으로 기능한다.

서사 출력 레이어에서는 유형별 파라미터가 반영된 LLM 출력이 JSON 스키마 형태로 구조화되며, 이는 Ren'Py 스크립트로 자동 변환 및 컴파일된다. 이 과정에서 각 장면(Scene)은 유형 정보, 감정 상태, 분기 조건 등을 포함한 메타데이터를 함께 기록하며, 이를 통해 후속 반복 생성 시 동일 유형에 대한 서사 스타일의 일관성을 유지할 수 있다. 또

한 이러한 메타데이터는 향후 사용자 행동 로그와 결합되어, 유형 추론 및 개인화 모델 개선에 활용될 수 있는 확장성을 가진다.

전체 파이프라인은 자연어 입력부터 플레이 가능한 빌드 산출까지를 하나의 흐름으로 연결하는 원스톱 구조를 유지하며, 비전문 사용자도 별도의 코딩 과정 없이 콘텐츠를 생성할 수 있도록 설계되었다. 특히 유형 파라미터 주입 방식은 기존 시스템 아키텍처에 최소한의 추가 모듈로 통합되도록 구성되어, 시스템 복잡도를 증가시키지 않으면서도 개인화 수준을 크게 향상시키는 경량 확장(lightweight extension) 구조를 가진다. 이와 유사하게 Husen and Istiono는 LLM과 Text-to-Image 모델을 결합한 단일 파이프라인으로 VN 스토리와 이미지를 자동 생성하고 고유성을 정량 검증함으로써, 통합 파이프라인 방식의 실무적 유효성을 실증하였다[11].

결과적으로 본 접근 방식은 고정된 서사 생성 구조와 유연한 개인화 제어 메커니즘을 결합한 하이브리드 설계로, 다양한 사용자 유형에 대응하는 적응형 내러티브 생성 시스템의 구현 가능성을 제시한다. 한편 Alharthi는 생성 AI 도구 사용자 연구를 통해 유형별로 창의 의존성과 인지 부하가 다르게 나타남을 확인하였으며, 이는 사용자 특성에 따른 서사 제약 설계가 실무적으로 유효함을 지지한다[12].

V. 통계 분석 결과

5-1 신뢰도 및 회귀 분석

측정 도구의 신뢰도는 선행 연구[1]의 분석 결과와 일관되게, 인지 부하($\alpha=.859$)가 가장 높은 내적 일관성을 보였으며, 창의성 지원($\alpha=.638$)은 수용 가능한 수준을 충족하였다. 제작효율 인식($\alpha=.587$)과 사용 용이성($\alpha=.564$)은 기준치(.60)에 근접하여 탐색적 분석 수준에서 활용하였으며, 재사용 의향($\alpha=.532$)은 기준치에 미달하여 항목별 개별 분석하였다. α 미달 척도들은 탐색적 분석 수준에서 해석하며, 향후 문항 수 확대 및 척도 재설계를 통한 신뢰도 개선이 필요하다.

선행 연구[1]에서 생산성 인식은 재사용 의향 변량의 39.9%를 설명하는 가장 강력한 예측 변수로 확인된 바 있다($\beta=.677$, $R^2=.399$, $p<.001$). 본 연구의 표본($N=145$)에서도 생산성 인식(Q7)이 재사용 의향(Q22)에 유의한 정적 영향을 미치는 것으로 나타나($\beta=.264$, $R^2=.054$, $p=.005$), 선행 연구[1]의 결과와 일관된 방향을 확인하였다. 다만 설명력($R^2=.054$)이 선행 연구 대비 낮은 수준으로, 이는 본 연구가 창작자 유형이라는 조절변수를 추가함에 따라 생산성 인식 외 유형 특성이 재사용 의향에 추가적으로 영향을 미치고 있음을 시사한다. 유형별 주요 척도 평균을 비교한 일원분산분석에서는 Learner 유형이 사용 용이성($M=6.08$)과 재사용 의향($M=5.85$) 모두에서 가장 높은 점수를 보였으나, 유형 간

통계적 차이는 유의하지 않았다($p>.05$). 이는 AI 역할 인식 유형이 재사용 의향의 방향성보다 내러티브 생성 스타일 선호에 더 강하게 작용함을 시사하며, 유형별 파이프라인 파라미터 설계의 근거를 뒷받침한다.




그림 4. 창작자 유형별 주요 지표(7점 리커트 척도)
Fig. 4. Key metrics by creator type (7-point Likert scale)

5-2 창작자 유형별 제작 효율 인식 및 결과물 수정 비율 비교

선행 연구[1]에서 VN-AI Studio 사용 시 제작 시간이 기존 방식 대비 평균 97.7% 단축됨이 확인된 바 있으며, 생산성 인식이 도구 재사용 의향의 핵심 예측 변수임이 실증되었다. 본 연구는 이를 전제로, 창작자 유형에 따라 제작 효율 인식과 결과물 수정 비율에 차이가 나타나는지 탐색적으로 분석하였다.

AI 역할 인식 유형과 결과물 수정 필요 비율 간의 관계를 분석한 결과, Co-Creator 유형($M=19.6\%$), Director 유형($M=22.3\%$), Craftsman 유형($M=16.4\%$), Learner 유형($M=16.7\%$) 간 차이가 관찰되었으나 통계적으로 유의하지 않았다($F(3,122)=0.73$, $p=.536$). 이는 결과물 수정 행동이 창작자 유형보다 개인의 완성도 기준이나 작업 목적에 더 크게 영향받을 수 있음을 시사한다.

인지 부하 척도에서는 Director 유형이 $M=2.92$ 로 가장 높은 부하를 보고하였으며, 이는 게임 내 인지 부하 측정 방법론[13]과 일관된 방식으로 분석되었다. 이는 서사 구조를 직접 제어하고 결과를 명시적으로 관리하려는 Director 유형의 특성상, 동일한 도구 사용 환경에서도 인지적 비용이 상대적으로 높게 인식됨을 의미한다. 반면 Craftsman 유형과 Learner 유형은 상대적으로 낮은 인지 부하를 보고하여, AI를 기능 도구 또는 학습 매개체로 인식하는 유형에서 인지적 부담이 적게 나타나는 경향을 확인하였다. 이러한 유형별 인

지 부하 차이는 4장에서 제안한 유형별 파라미터 설계의 타당성을 간접적으로 지지하는 근거로 해석된다.

VI. 개념 검증(PoC): 유형별 내러티브 분기 생성

6-1 실험 설계 및 결과

제안 파이프라인의 유효성을 검증하기 위해 동일한 프롤로그 설정에서 4개 유형별 파라미터를 각각 적용하여 내러티브 분기를 생성하는 개념 검증 실험을 수행하였다. 이는 AI 도구 기반 제작 워크플로우 검증 방식[14]을 준용하였다. 프롤로그는 “폐쇄된 우주 정거장에서 원인 불명의 정전이 발생하고, 주인공은 혼자 비상 전원을 복구해야 한다”는 동일 설정을 사용하였다. 실험에 사용된 LLM은 Google Gemini Pro(JSON Mode)이며, $temperature=0.7$, $max_tokens=512$ 로 설정하였다. 각 유형의 파라미터를 Gemini Pro에 주입하여 ‘전(轉)’ 단계의 핵심 분기 장면을 생성하고, 생성된 텍스트를 Sentence-BERT 임베딩 벡터로 변환한 후 코사인 유사도를 측정하였다.

Sun 외는 Drama Llama 프레임워크를 통해 LLM 기반 storylet 분기 자동화가 인터랙티브 픽션 저작 생산성을 향상시킬 수 있음을 실증하였으며, 이는 본 실험의 유형별 분기 생성 접근과 유사한 방향을 공유한다[15].

유사도 분석 결과, 4개 유형 간 평균 코사인 유사도는 0.31로 나타났다. 가장 낮은 유사도는 Co-Creator와 Craftsman 유형 간(0.19)이었으며, 가장 높은 유사도는 Director와 Co-Creator 유형 간(0.44)이었다. 두 유형 모두 능동적 에이전시(Agency)와 명확한 목표 지향성을 공유하고 있어, AI 역할 인식 방식은 다르나 서사 구조적 선호(갈등 중심 분기, 결과 명시)가 부분적으로 중첩된 결과로 해석된다.

두 유형을 보다 명확히 분리하기 위해서는 세분화된 파라미터 설계 또는 행동 로그 기반 정교화가 향후 과제로 남는다. Co-Creator 유형은 등장인물 간의 감정적 갈등과 협력적 선택지를 중심으로 분기가 구성된 반면, Craftsman 유형은 기능적 문제 해결 절차와 단선적 행동 선택지로 구성되어 서사

표 4. 창작자 유형별 생성된 내러티브간 코사인 유사성

Table 4. Cosine similarity between generated narratives by creator type

Type Pair	Cosine Similarity	Narrative Difference
Co-Creator – Director	0.44	Highest (overlapping structure)
Co-Creator – Craftsman	0.19	Lowest (most distinct)
Director – Craftsman	0.28	Moderate
Learner – All (avg.)	0.33	Moderate
Overall Average	0.31	–

스타일의 명확한 차이를 보였다. Director 유형은 각 선택지의 결과를 명시적으로 예측하는 구조적 분기를 생성하였으며, Learner 유형은 상황 설명과 힌트가 포함된 교육적 내러티브 특성을 보였다.

Ⅶ. 결 론

7-1 연구 요약 및 기여

본 연구는 생성형AI 기반 비주얼 노벨 저작 환경에서 나타나는 창작자 유형을AI 역할 인식 방식에 따라 Co-Creator, Director, Craftsman, Learner의 4유형으로 분류하고, 각 유형의 특성을LLM 프롬프트 파라미터에 매핑하는 적응형 내러티브 분기 생성 파이프라인을 제안하였다. N=145의 실증 데이터 분석을 통해 직무 범주와 창작자 유형 간의 통계적으로 유의한 분포 차이를 확인하였으며($\chi^2=35.38$, $p<.001$). 선행연구[1]에서, 실증된 제작 시간 단축 효과와 일관되게, 본 표본에서도 유사한 단축 경향이 확인되었다. PoC 실험에서는 동일 프롤로그에서 유형별로 의미론적으로 차별화된 분기 내러티브가 생성됨을 코사인 유사도(평균 0.31)로 확인하였다.

본 연구의 학술적 기여는 두 가지이다. 첫째, 기존AI 저작 도구 연구가 평균적 효율 향상에 초점을 두었다면, 본 연구는 사용자 유형 다양성을 내러티브 생성 설계에 통합하는 개인화 관점을 제시하였다. 둘째, AI 역할 인식이라는 단일 측정 항목으로부터 내러티브 스타일 선호를 추론하는 실용적 유형 분류 체계를 제안함으로써, 복잡한 플레이어 모델링 없이도 적응형 콘텐츠 생성이 가능함을 보였다. 실무적 측면에서는 VN-AI Studio 파이프라인에 최소한의 모듈 추가로 구현 가능한 설계를 제시하여 소규모 팀과 1인 개발 환경에서의 즉각적 활용 가능성을 높였다.

7-2 한계 및 향후 연구

본 연구는 다음과 같은 한계를 가진다.

첫째, 창작자 유형 분류가 단일 항목(Q40)에 의존하여 측정되었기 때문에, 창작 행위의 다차원적 특성을 충분히 반영하지 못하였다. 향후 연구에서는 다문항 척도 및 실제 제작 로그 기반의 행동 지표를 병행하여 분류 타당성을 강화할 필요가 있다.

둘째, 일부 척도가 신뢰도 기준에 미달($\alpha<.60$)하였으며, 회귀분석의 설명력($R^2=.054$) 역시 제한적이어서 결과 해석 시 탐색적 수준으로 받아들여야 한다.

셋째, 제작 시간 비교는 자기보고 방식에 의존하며 단일 장면 수준의 제한적 과제를 기준으로 하므로, 복잡한 제작 환경에서의 효과는 추가 검증이 필요하다.

넷째, PoC 실험이 제한된 규모에서 수행되어 유형별 파라

미터의 최적값을 체계적으로 탐색하는 데 한계가 있으며, 생성된 내러티브에 대한 실제 플레이어의 만족도 평가가 이루어지지 못하였다.

이에 기반하여, 향후 연구 방향으로 다음의 세 가지를 제안한다.

첫째, 실시간 플레이 로그를 기반으로 창작자 및 플레이어의 유형을 동적으로 추론하는 모듈을 개발하고, 게임 진행 중 유형 변화에 따라 내러티브를 적응적으로 재구성하는 동적 개인화 서사 시스템을 구축한다.

둘째, 멀티 에이전트(Multi-Agent) 구조를 도입하여 유형별 서사 생성 에이전트가 병렬적으로 다양한 분기 시나리오를 생성하고, 평가 및 선택 에이전트가 최적의 결과를 선택하는 Generate-then-Select 기반 생성 구조를 설계함으로써, 서사 다양성과 품질을 동시에 향상시킨다.

셋째, 텍스트 중심의 생성 구조를 넘어 BGM 및 효과음 생성 모델을 포함한 멀티모달 저작 환경으로 확장하여, 유형별 감정 톤과 서사 흐름에 정합적인 시청각 콘텐츠를 자동 생성하는 통합 개인화 콘텐츠 생성 파이프라인을 완성한다.

종합하면, 본 연구는 창작자 유형 기반의 분기 내러티브 생성이라는 초기 접근을 통해 개인화된 콘텐츠 생성의 가능성을 제시하였으며, 향후에는 행동 데이터 기반의 정밀한 유형 모델링, 멀티 에이전트 협업 구조, 그리고 멀티모달 확장을 통해 보다 고도화된 개인화 서사 생성 시스템으로 발전할 수 있을 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] T. Kim and T. Kim, "Perceived Production Efficiency and Workflow Redesign in a Generative AI-Based Visual Novel Authoring Tool," *Journal of Digital Contents Society*, 2026.
- [2] 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 *Proceedings of the IEEE Conference on Games (CoG)*, Milan, Italy, August 2024. <https://doi.org/10.1109/CoG60054.2024.10645553>
- [3] Y. Bole, "Integrating Generative AI into Game Development

- Pipelines: A User Centered Approach to Creative Efficiency,” *Information Systems Student Research Journal (ISSRJ)*, Vol. 1, Digest 3, pp. 1-4, 2025.
- [4] R. A. Bartle, “Hearts, Clubs, Diamonds, Spades: Players Who Suit MUDs,” *Journal of MUD Research*, Vol. 1, No. 1, p. 19, 1996.
- [5] N. Yee, “Motivations for Play in Online Games,” *Cyberpsychology Behavior, and Social Networking*, Vol. 9, No. 6, pp. 772-775, December 2006. <https://doi.org/10.1089/cpb.2006.9.772>
- [6] P. Taveekitworachai, C. Nimpattavong, M. C. Gursesli, A. Lanata, A. Guazzini, and R. Thawonmas, “Multiverse of Greatness: Generating Story Branches with LLMs,” arXiv:2411.14672, November 2024. <https://doi.org/10.48550/arXiv.2411.14672>
- [7] V. Kumaran, J. Rowe, B. Mott, and J. C. Lester, “SceneCraft: Automating Interactive Narrative Scene Generation in Digital Games with Large Language Models,” *Proceedings of the 19th AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment*, Vol. 19, No. 1, pp. 86-96, October 2023. <https://doi.org/10.1609/aiid.e.v19i1.27504>
- [8] P. Bhandari, N. Fay, M. Wise, A. Datta, S. Meek, U. Naseem, and M. Nasim, “Can LLM Agents Maintain a Persona in Discourse?,” arXiv:2502.11843, February 2025. <https://doi.org/10.48550/arXiv.2502.11843>
- [9] T. Kim and T. Kim, “Quantitative Analysis of Linguistic Expression Differences in AI Characters Based on the Big Five Model in LLM Text Simulations,” *Journal of Digital Contents Society*, Vol. 27, No. 3, pp. 793-801, March 2026.
- [10] Y. Li, H. L. Siek, and J. Guo, “An Empirical Study on the Use Behavior Towards AI Painting Tools Based on TAM3 Model,” *Scientific Reports*, Vol. 15, 40533, 2025. <https://doi.org/10.1038/s41598-025-24405-w>
- [11] D. Hutama Husen and W. Istiono, “Procedural Story Generation for Visual Novels Using Large Language Models and Text-to-Image Techniques,” *Journal of Games, Game Art and Gamification (JGGAG)*, Vol. 10, No. 3, pp. 106-114, 2025.
- [12] S. A. Alharthi, “Generative AI in Game Design: Enhancing Creativity or Constraining Innovation?,” *Journal of Intelligence*, Vol. 13, No. 6, 60, May 2025. <https://doi.org/10.3390/jintelligence13060060>
- [13] N. Sevchenko, M. Ninaus, F. Wortha, K. Moeller, and P. Gerjets, “Measuring Cognitive Load Using In-Game Metrics of a Serious Simulation Game,” *Frontiers in Psychology*, Vol. 12, 572437, March 2021. <https://doi.org/10.3389/fpsyg.2021.572437>

- [14] E. Adriana and B. Song, “Study of Production Workflows in Interactive 3D Animation with AI Applications,” *International Journal of Contents*, Vol. 20, No. 4, pp. 68-74, December 2024. <https://doi.org/10.5392/IJoC.2020.20.4.068>
- [15] Y. Sun, P. J. Wang, J. J. Y. Chung, M. Roemmele, T. Kim, and M. Kreminski, “Drama Llama: An LLM-Powered Storylets Framework for Authorable Responsiveness in Interactive Narrative,” arXiv:2501.09099, January 2025. <https://doi.org/10.48550/arXiv.2501.09099>



김태완(Taewan Kim)

2002년 : 부산대학교 예술대학
미술학과

2017년 : 가천대학교
게임대학원(게임학 석사)

2024년~현 재: 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(Tae-hoon 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)