

생성형 인공지능을 활용한 2D 게임 그래픽 에셋 제작 연구 동향

A Survey on Generative AI-driven 2D Game Graphic Asset Production

김은정¹, 김정윤^{2*}

Eun Joung Kim¹, JungYoon Kim^{2*}

요약

게임 개발에서 2D 그래픽 에셋은 플레이 경험과 게임 아이덴티티를 규정하는 핵심 요소이지만, 캐릭터 스프라이트, 타일셋, 배경, 이펙트, UI 아이콘 등 대부분 수작업에 의존하고 있어 제작비용과 반복 노동이 크게 발생한다. 전통적인 절차적 콘텐츠 생성은 레벨, 규칙, 스토리와 같은 구조적 콘텐츠 자동화에는 효과적이지만, 미술 스타일과 디렉션을 엄격히 요구하는 2D 그래픽 에셋 영역에서는 한계를 드러내 왔다. 최근 생성적 적대 신경망, 이미지-이미지 변환 모델, 확산 모델 등 생성형 인공지능(AI)의 발전으로 2D 게임 그래픽 에셋의 자동 생성, 보완, 변환 가능성이 빠르게 확장되고 있다. 본 논문은 생성형 AI 기반 2D 게임 그래픽 에셋 제작 연구를 대상으로, 첫째, 절차적 콘텐츠 생성과 생성형 모델, 그래픽 에셋 프레임워크에 대한 이론적 배경, 둘째, 캐릭터, 애니메이션, 이펙트 중심의 기술 동향, 셋째, 생성형 AI를 통합한 혼합 주도형 에셋 제작 파이프라인, 넷째, 2D 게임 특성을 반영한 평가 지표 및 벤치마크, 마지막으로, 게임 아티스트 관점의 수용과 인간-AI 협업 구조를 중심으로 선행 연구를 정리한다. 분석 결과, 생성형 AI는 2D 게임 그래픽 에셋 제작의 효율성과 표현력을 동시에 확장할 잠재력을 지녔지만, 도메인 일반화, 프레임 일관성, 타일링, 팔레트 제약, 저작권과 데이터셋 출처, 아티스트 역할 재구성 등 해결해야 할 과제도 여전히 존재함을 확인하였다.

핵심어 : 생성형 인공지능, 절차적 콘텐츠 생성, 게임 그래픽 에셋, 2D 스프라이트, 픽셀 아트, 생성적 적대 신경망, 확산 모델

Abstract

In game development, two-dimensional (2D) graphic assets are core elements that define player experience and game identity, yet the production of character sprites, tilesets, backgrounds, effects, and UI icons still depends heavily on manual work, so that it results in substantial production costs and repetitive labor. Traditional procedural content generation (PCG) has proven effective for automating structural content such as levels, rules, and stories, but it has shown clear limitations in domains like 2D graphic assets, where strict control over art style and direction is required. Recent studies in generative adversarial networks, image-to-image translation models, and diffusion-based generative AI have rapidly expanded the possibilities for automatic generation, enhancement, and transformation of 2D game graphic assets. Focusing on research into generative AI-based 2D game graphic asset production, this paper surveys prior work along five dimensions: the theoretical background of PCG, generative models, and graphical asset

1 Department of Game Contents, Kyungil University, Gyeongsan, Korea [Professor]
e-mail: eunjoungkim@kiu.ac.kr

2 Department of Game Media, College of IT Convergence, Gachon University, Korea [Professor]
e-mail: kjyoon@gachon.ac.kr (Corresponding author)

Received(September 18, 2025), Review Result(1st: October 5, 2025), Accepted(November 12, 2025), Published(November 30, 2025)



© 2025 The Authors. Published by NCISS.
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

frameworks technical trends centered on characters, animations, and effects mixed-initiative asset production pipelines that integrate generative AI evaluation metrics and benchmarks that reflect the characteristics of 2D games and game artists' acceptance of these technologies and emerging structures of human - AI collaboration. The analysis indicates that generative AI has the potential to simultaneously enhance efficiency and expressiveness in 2D game graphic asset production, while also revealing remaining challenges in domain generalization, frame consistency, tiling and palette constraints, copyright and dataset provenance, and the reconfiguration of artist roles.

Keyword : Generative artificial intelligence, Procedural content generation, Game graphic assets, 2D sprites, Pixel art, GANs, Diffusion models

1. 서론

게임 개발에서 그래픽은 플레이어의 몰입과 게임의 미학적 아이덴티티를 형성하는 핵심 요소이다. 특히 2D 게임의 경우, 캐릭터 스프라이트, 타일셋, 배경, 이펙트, UI 아이콘 등 대부분의 시각 요소가 수작업으로 제작되며, 이는 높은 예술적 역량뿐 아니라 상당한 시간과 노동을 요구한다. 일례로, 픽셀 아트 캐릭터의 포즈가 변경되거나 장식, 색상 요소가 수정될 때, 수백 장에 이르는 스프라이트를 일일이 반복 편집해야 하는 비효율성은 대표적인 문제이다.

이러한 제작 비용과 반복 작업 문제를 해결하기 위해 절차적 콘텐츠 생성(Procedural Content Generation, PCG)이 오랫동안 연구되어 왔다 [1][2]. 그러나 절차적 콘텐츠 생성은 규칙 또는 탐색 기반 알고리즘을 통해 레벨 구조, 아이템 배치 등과 같은 구조적 콘텐츠를 생성하는 데는 효과적이지만, 특정 미술 스타일과 컨셉 방향을 유지하면서 2D 그래픽 에셋을 제작에서는 한계를 보였다. 최근에는 생성적 적대 신경망(Generative Adversarial Network, GAN), 변분 오토인코더(Variational Autoencoders, VAE), 확산 모델(diffusion models) 등 생성형 인공지능(Generative AI)의 발전으로, 2D 게임 그래픽 에셋의 자동 생성, 보완, 변환에 대한 관심이 급격히 확대되고 있다 [3-5].

본 논문은 생성형 AI를 활용한 2D 게임 그래픽 에셋 제작 연구를 체계적으로 검토한다. 구체적으로 (1) 절차적 콘텐츠 생성, 생성형 모델, 그래픽 에셋 프레임워크에 대한 이론적 배경, (2) 픽셀 아트, 스프라이트, 이펙트 중심의 기술 동향, (3) 생성형 AI를 통합한 에셋 제작 파이프라인, (4) 2D 게임 그래픽 에셋 평가 지표 및 벤치마크, (5) 게임 아티스트 관점의 수용과 협업 구조를 중심으로 최근 연구를 분석한다. 이를 바탕으로 향후 연구 과제와 실무 적용을 위한 방향성을 제시하고자 한다.

2. 이론적 배경

2.1 절차적 콘텐츠 생성과 게임 그래픽 에셋

절차적 콘텐츠 생성은 수작업 제작의 비용과 확장성 한계를 완화하기 위한 핵심 개념으로, 게임

의 맵, 레벨, 아이템, 규칙, 스토리 등을 알고리즘을 통해 자동으로 생성하는 기법이다. 기존 연구와 산업 현장에서는 절차적 콘텐츠 생성을 게임환경에 적용하는 포괄적 틀 안에서, 비트 수준의 저수준 요소부터, 공간, 시스템, 시나리오, 디자인, 파생 콘텐츠에 이르기까지 생성 대상과 알고리즘을 광범위하게 분류해왔다 [1][2].

그러나 기존의 절차적 콘텐츠 생성 연구는 주로 구조적 콘텐츠에 초점을 두고 있으며, 개별 2D 그래픽 에셋의 미적 품질이나 아티스트 스타일을 세밀하게 반영하는 데에는 한계가 있다. 2D 캐릭터 스프라이트, 타일셋, 배경, 이펙트 이미지, UI 아이콘 등은 단순히 기능적 요구를 넘어 일정 수준 이상의 예술적 완성도와 스타일 가이드를 요구하기 때문에, 규칙 기반 절차적 콘텐츠 생성만으로 실제 제작 현장의 요구를 충족하기 어렵다. 이로 인해 그래픽 에셋을 별도 연구 대상으로 설정하고, 딥러닝 기반 생성형 모델과 결합하려는 시도가 등장하게 되었다 [6].

2.2 생성형 모델 아키텍처

딥러닝 기반 생성형 모델은 게임 그래픽 에셋의 자동 생성, 보완, 변환을 위한 기술적 토대이다. 생성적 적대 신경망은 생성자와 판별자를 경쟁적으로 학습시켜 목표 데이터 분포를 모사하는 구조로, 이미지 합성 전반의 기본 이론을 제공한다. 이후 DCGAN(Deep Convolutonal Generative Adversarial Network)은 합성곱 구조와 배치 정규화를 도입해 저·중 해상도 이미지 생성에서 학습 안정성과 표현력을 크게 개선하였고, 아이콘, 아이템, 픽셀 아트 생성에 널리 활용되었다.

cGAN 기반 이미지-이미지 변환 모델(Pix2Pix)은 입력 이미지를 조건으로 활용해 라벨맵에서 사진 생성, 선화에서 채색, 스타일 전이 등을 수행하는 프레임워크를 제시하였다. 이는 픽셀 아트 캐릭터의 포즈 변환, 흑백 선화에서 컬러 스프라이트로의 변환, 다른 스타일의 도트 그래픽으로 간 변환 등 게임 그래픽의 실질적 변환 문제에 직접 적용가능하다 [7][8]. 여기에 다중 도메인, 멀티 디스크리미네이터 구조를 도입하면 색상, 형태, 애니메이션 속성을 분리 및 조합하여 다양한 스프라이트 변형을 효율적으로 생성할 수 있다 [8-10].

한편, 확산 모델은 점진적으로 노이즈를 제거하는 역과정을 학습하여 고품질 이미지를 생성하는 방식이다. 특히, 잠재 확산 모델(Latent Diffusion Model, LDM)은 오토인코더 잠재 공간에서 확산 과정을 수행함으로써, 고해상도 이미지를 효율적으로 합성한다. 텍스트 조건부 이미지 생성뿐 아니라, 스프라이트 시트를 하나의 큰 이미지로 간주하고, 포즈, 레이아웃 정보를 조건으로 활용해 일관된 애니메이션 프레임을 생성하는 연구에도 적용되고 있다 [11].

정리하면, 생성적 적대 신경망, cGAN, 이미지-이미지 변환 모델은 주로 아이콘, 픽셀 아트, 이펙트 스프라이트와 같은 저·중 해상도 2D 에셋 생성에 적합하고, 확산 모델은 고해상도 이미지나 복잡한 스프라이트 시트와 같이 디테일과 프레임 간 일관성이 중요한 에셋에 강점을 보인다.

2.3 그래픽 게임 에셋 생성, 변환 프레임워크와 평가

그래픽 게임 에셋을 대상으로 한 개념적 프레임워크와 평가 체계도 최근 활발히 제안되고 있다. GAGeTx(Graphical Asset Generation and Transformation) 프레임워크는 그래픽 에셋의 생성 및 변환 연구를 입력 유형(텍스트, 스케치, 파라미터, 예제 이미지 등), 알고리즘 범주, 접근 방식, 타겟 에셋 유형에 따라 분류한다. 이를 통해 특정 에셋이나 작업 유형에 어떤 기법이 적용되어 왔는지 구조적으로 파악할 수 있다 [12].

그래픽 에셋 생성 방법의 성능을 평가하기 위한 지표는 흔히 아티팩트 유효성, 아티팩트 품질, 작동 지표와 같은 세 가지 범주로 구분된다. 아티팩트 유효성 지표는 FID(Frechet Inception Distance), IS(Inception Score), SSIM(Structural Similarity Index), PSNR(Peak Signal-to-noise ratio), LPIPS(Learned Perceptual Image Patch Similarity) 등이 포함된다. 아티팩트 품질 지표에는 BRISQUE(Blind/Referenceless Image Spatial Quality Evaluator), PIQE(Perception based Image Quality Evaluator), NIQE(Natural Image Quality Evaluator) 등 무참조(no-reference) 품질 지표가 사용된다. 작동 지표는 메모리 사용량, 처리 속도, 시간 복잡도 등 시스템 관점의 성능을 의미한다. 이러한 일반적 평가 프레임워크는 2D 게임 그래픽 에셋의 특수성을 반영한 평가 기준으로 확장될 수 있다. 예를 들어, 타일링 가능 여부, UI 및 아이콘 판독성, 픽셀 아트 스타일 유지, 스프라이트 시트 내 프레임 일관성 등을 확장 및 설계하는 근거가 된다.

또한 생성형 그래픽 에셋 도구를 실제 사용하는 게임 디자이너와 개발자의 요구 사항 및 사용 경험을 분석한 연구는 도구 설계에 필요한 제어 가능성, 결과의 예측 가능성, 반복적 실험, 수정을 지원하는 인터페이스 디자인의 중요성을 강조한다. 이는 이후 장에서 다룰 혼합 주도 (mixed-initiative) 파이프라인과 인간-AI 협업 구조에 대한 이론적 근거를 제공한다 [13].

3. 생성형 AI 기반 2D 게임 그래픽 에셋 생성 기술 동향

이 장에서는 2D 게임 그래픽 에셋을 대상으로 한 생성형 AI 기술을 에셋 유형과 모델 관점에서 정리한다. 주요 대상은 아이콘, UI, 픽셀 아트 캐릭터, 스프라이트, 이펙트 스프라이트, 스프라이트 시트, 애니메이션, 채색, 스타일 전이 도구 등이다.

3.1 생성적 적대 신경망 기반 2D 아이콘 및 UI 생성

초기 연구들은 DCGAN 변형 모델을 활용해 판타지나 SF 컨셉의 게임 아이콘이나 아이템 그래픽을 자동 생성하는 데 집중했다. 이들 연구는 소규모 아이콘 데이터셋으로 생성적 적대 신경망을 학습해 인간이 그린 것과 유사한 품질의 2D 아이콘을 생성하고, FID와 사용자 블라인드 테스트로

품질을 평가한다. 실험결과, 상당수의 사용자가 생성 이미지를 실제 제작 에셋으로 인식할 정도의 시각적 신뢰성이 검증되었다.

이러한 아이콘 생성 연구는 인벤토리 아이템, UI 버튼, 카드 일러스트 등 반복적 변주가 필요한 2D 에셋을 위해 후보 이미지를 자동으로 생성하고, 디자이너가 이를 선택·수정하는 방식의 워크플로를 제안한다. 다만, 세밀한 의미 제어와 철저한 스타일 가이드 준수 측면에서는 여전히 한계가 지적된다.

3.2 픽셀 아트 캐릭터, 스프라이트 생성

픽셀 아트 캐릭터 생성 연구는 크게 두 가지 접근으로 나뉜다. 첫째, 이미지-이미지 변환 모델을 사용해 입력 스케치나 실사 이미지를 픽셀 아트 스타일로 변환하는 방식이다. Pix2Pix 계열 모델은 네트워크 용량, 색상 채널 수, 판별자 패치 크기 등을 조정하여, 저해상도 픽셀 아트 특성에 맞게 최적화되며, 캐릭터 스케치를 입력하면 자동으로 픽셀 아트 스프라이트를 생성할 수 있다.

둘째, 다중 판별자 GAN을 통해 색상, 형태, 애니메이션 정보를 분리하고 조합하는 방식이다. 이러한 모델은 하나의 모션에 여러 색상 팔레트와 장신구 변형을 더하는 데 유리하며, 캐릭터 스킨이나 의상 변형을 대량으로 생성하는 데 활용될 수 있다. 그러나 복잡한 포즈나 관절 움직임에서 시각적 결함이 발생하기 쉽고, 픽셀 아트 고유의 도트 감도, 윤곽선 표현을 완전히 자동화하는 데에는 여전히 한계가 있다.

3.3 이펙트 스프라이트 생성

불꽃, 폭발, 마법, 연기 등의 이펙트 스프라이트는 시각적 다양성과 스타일 일관성을 동시에 요구하는 에셋이다. 소량의 샘플 데이터로 다양한 스타일의 이펙트를 생성하기 위해 cGAN을 활용한 연구가 제안되었다. 이 접근법은 구조 이미지와 스타일 레이블을 입력으로 받아, 최소한의 데이터로도 스타일 일관성이 높은 이펙트 스프라이트를 생성하는 것이 특징이다.

이러한 방식은 VFX 아티스트가 제작한 소수의 참조 이미지를 기반으로 대량의 변형을 생성할 수 있어, 이펙트 작업의 부담을 크게 줄일 수 있는 잠재력을 갖는다. 다만, 게임 내 물리, 타이밍과의 정합성까지 구현에 있어 한계점이 있으며, 완전히 새로운 개념의 이펙트를 발명하기보다는 기존 스타일의 변화에 더 적합하다는 제약이 있다.

3.4 스프라이트 시트 및 애니메이션 보정 및 생성

애니메이션 스프라이트 시퀀스를 대상으로 한 연구는 크게 보정형과 직접 생성형으로 구분할 수 있다.

보정형 접근에서는 완전한 스프라이트 시트가 아닌 일부 키프레임이나 포즈만 존재할 때, 누락된 프레임이나 방향을 보간·복원하는 GAIN(Missing Data Imputation using Generative Adversarial Nets)이 제안된다. 이 모델은 관찰 가능한 포즈들 간 관계를 학습하여, 누락된 포즈를 자연스럽게 채워 넣는다. 이를 통해 애니메이터는 핵심 포즈만 제작하고, 나머지 프레임은 모델이 자동으로 생성하는 혼합 주도 워크플로를 구현할 수 있다.

직접 생성형 접근에서는 캐릭터 참조 이미지와 포즈 시퀀스, 혹은 ‘걷기’, ‘뛰기’, ‘공격’ 등의 행동 태그를 조건으로 전체 스프라이트 시트를 생성하는 확산 기반 모델이 등장하고 있다. Sprite Sheet Diffusion과 유사한 구조의 모델들은 스프라이트 시트를 하나의 대형 이미지로 간주하고, 프레임 간 일관성을 유지하도록 레이아웃 인지형 조건을 활용한다. 이는 단일 캐릭터 일러스트에서 전체 모션 셋을 자동 생성하는 가능성을 보여주지만, 여전히 인게임 활용을 위해서는 세밀한 후편집과 검수가 필요하다.

3.5 딥러닝 보조 채색 및 인간-기계 협업 기반 에셋 제작

완전한 자동 생성과 달리, 딥러닝 보조 채색 및 협업 도구는 인간 아티스트의 워크플로에 자연스럽게 통합되도록 설계된다. 예를 들어, 러프 스케치나 선화를 입력으로 받아 채색, 광원, 그라디언트를 자동으로 입히고, 아티스트가 이를 다시 수정하는 시스템이 제안되어 왔다. 픽셀 아트 스프라이트 시트 제작에서도 일부 프레임만 사람이 직접 채색하고 나머지는 모델이 보간하는 형태의 협업 방식이 보고되고 있다 [13].

이러한 도구는 최종 완성본을 대체하기보다, 반복적인 채색과 보간 작업을 줄이고 탐색 가능한 스타일과 구성을 확장하는 데 목적이 있다. 따라서 생성형 AI의 역할은 창의적 보조 도구로 정의되며, 최종적인 작업물 통제와 해석은 여전히 아티스트의 영역으로 유지된다.

4. 생성형 AI 기반 2D 게임 그래픽 에셋 제작 파이프라인

4.1 전통적 제작 파이프라인과 한계

전통적인 2D 게임 그래픽 에셋 제작 파이프라인은 아이디어 발상, 레퍼런스 수집, 컨셉 스케치, 클린업, 채색, 스프라이트 시트 제작, 인게임 테스트 및 수정 단계로 구성된다. 이 과정에서 캐릭터 회전 방향, 애니메이션 포즈, 다양한 장비, 스킨을 제작하려면 상당한 반복 작업이 필연적으로 발생한다. 특히 픽셀 아트 프로젝트의 경우, 작은 해상도에서의 디테일 조정과 타일 경계, 프레임 일관성 확인이 많은 시간을 소모하는 병목으로 작용한다.

4.2 생성형 AI 통합 파이프라인과 혼합 주도 시스템

생성형 AI를 통합한 2D 에셋 제작 파이프라인은 대체로 다음 [표 1]과 같은 혼합 주도 구조를 갖는다.

[표 1] AI를 통합한 2D 에셋 제작 파이프라인

[Table. 1] AI-Driven 2D Asset Production Pipeline

기획, 프롬프트 단계
<ul style="list-style-type: none"> • 텍스트 프롬프트, 레퍼런스 이미지, 러프 스케치를 기반으로, 생성형 모델을 사용해 다양한 컨셉 이미지와 스타일 후보를 생성한다. 이를 통해 아이디어 탐색과 레이아웃 구상이 빠르게 이루어진다.
초기 에셋 생성 단계
<ul style="list-style-type: none"> • 선택된 컨셉을 바탕으로 생성적 적대 신경망, 이미지-이미지 변환, 확산 모델 등을 활용해 아이콘, 캐릭터 스프라이트, 이펙트, 타일셋 등의 초기 버전을 생성한다. 픽셀 아트 변환, 포즈 전환, 스타일 전이 등이 이 단계에 포함된다.
후편집, 보정 단계
<ul style="list-style-type: none"> • 생성 결과를 기반으로 아티스트가 도트 편집, 타일 경계 조정, 색상, 팔레트 보정, 프레임 수정 등을 수행한다. 누락된 포즈나 프레임은 GAIN이 보완하고, 자동 채색 도구가 반복 작업을 덜어준다.
엔진 통합 및 검증 단계
<ul style="list-style-type: none"> • 생성, 보정된 에셋을 게임엔진에 가져와 실제 플레이 상황에서 판독성, 몰입감, 성능을 검증한다. 필요 시 다시 앞선 단계를 반복하여 최적화한다.

이 과정에서 생성형 모델은 초안 제안자와 반복 작업 보조자 역할을 담당하며, 최종 품질과 스타일 일관성을 확보하는 책임은 여전히 아티스트와 아트 디렉터에게 있다.

4.3 에셋 유형별 기술 매핑

에셋 유형별로 활용 가능한 생성형 기술을 정리하면 다음과 같다.

- 아이콘, 아이템, 카드 일러스트 - DCGAN 기반 이미지 생성, 조건부 생성적 적대 신경망을 통한 의미 조건 제어
- 캐릭터 스프라이트, 픽셀 아트 - 이미지-이미지 변환 기반 스타일 변환, MDGAN 기반 색상, 형태 변형 생성, GAIN 기반 프레임 보간
- 이펙트 스프라이트 - GESGAN과 같은 조건부 생성적 적대 신경망을 통한 구조, 스타일 분리 및 스타일 전이
- 스프라이트 시트, 애니메이션 - 확산 모델 기반 스프라이트 시트 직접 생성, 비디오 생성 모델을 이용한 포즈, 모션 기반 시퀀스 생성

- 채색, 스타일 보조 - 딥러닝 기반 자동 채색, 스타일 전이, 도트 리터칭 보조 도구

이러한 기술 매핑은 게임 개발 스튜디오가 특정 에셋 작업에 어떤 종류의 생성형 모델을 도입할지 결정하는 데 참고가 될 수 있다.

4.4 개발 도구, 엔진과의 통합

실무 환경에서는 생성형 AI가 독립된 연구용 코드가 아니라 DCC(Digital Contents Creatioin) 소프트웨어와 게임엔진 환경에 자연스럽게 통합되어야 한다. 플러그인 형태로 프롬프트 입력, 결과 미리보기, 레이어 분리, 타일, 스프라이트 시트 출력까지 제공하는 도구가 제안되고 있으며, 아티스트가 익숙한 UI 안에서 생성형 기능을 활용할 수 있도록 하는 것이 중요하다. 또한 버전 관리, 협업 워크플로, 자동 빌드 파이프라인과의 연계도 실무 적용에서 고려되어야 할 요소이다.

5. 2D 게임 그래픽 에셋 평가 지표 및 벤치마크

5.1 시각 품질 평가 지표

2D 생성형 에셋의 시각적 품질을 정량적으로 평가하기 위해 FID, IS, LPIPS, SSIM, PSNR 등 다양한 지표가 사용된다. 아이콘, 픽셀 아트 생성 연구에서는 생성 이미지와 실제 자산 간 분포 차이, 구조적 유사성, 세부 텍스처 보존 정도를 측정해 모델 성능을 비교한다. 그러나 이러한 지표는 일반 자연 이미지에 최적화된 특징 추출기를 사용하는 경우가 많아, 픽셀 아트 특유의 도트 감도나 제한된 팔레트 특성을 충분히 반영하지 못하는 한계가 있다.

5.2 2D 게임 특화 평가 요소

2D 게임 그래픽 에셋은 일반 이미지와 달리 도메인 특화 관점에서의 품질 평가가 요구된다. 특히 타일셋, 배경 텍스처 등 반복 사용되는 그래픽 요소의 경우 경계가 노출되지 않고 패턴의 반복이 부자연스럽지 않은지가 중요한 기준이 된다. 또한 아이콘, UI, 캐릭터 실루엣과 같이 기능적 정보 전달을 수행하는 시각 요소에서는 시각적 판독성이 확보되어, 사용자에게 역할과 의미가 즉시 구분되는지 여부가 핵심적으로 고려된다. 프로젝트의 전체 아트 디렉션과 색상 팔레트에 대한 일관된 적용 여부는 그래픽 스타일의 통일성을 판단하는 주요 지표가 된다. 스프라이트 기반 애니메이션에서는 프레임 간 비율, 윤곽, 동작 흐름이 자연스럽게 유지되는지 여부가 품질에 직접적으로 영향을 미친다. 이러한 요소들은 자동화된 지표만으로 정량적 평가가 어렵기 때문에, 아티스트와 디자이너, 실제 플레이어의 평가와 병행하여 종합적으로 판단하는 방식이 일반적으로 활용된다.

5.3 평가 프레임워크 적용

그래픽 게임 에셋 평가 프레임워크는 위에서 언급한 아티팩트 유효성, 품질, 작동 지표를 통합적으로 고려하여, 특정 모델, 파이프라인의 강점과 약점을 분석하는 데 활용될 수 있다. 2D 에셋 관점에서는 아티팩트 유효성 지표에 픽셀 아트 전용 특징 추출기를 도입하거나, 품질 지표에 도메인 특화 무참조 평가를 추가하고, 작동 지표에서 편집 도구와의 상호작용 속도, 응답성을 중시하는 방향으로 확장하는 것이 적절하다.

5.4 휴먼 평가와 사용자 경험

정량 지표만으로는 실제 게임 경험에 미치는 영향을 충분히 설명하기 어렵기 때문에, 아티스트, 디자이너, 플레이어를 대상으로 한 휴먼 평가가 중요하다. 아티스트, 디자이너 평가에서는 작업 편의성, 수정 용이성, 창의성 지원 정도, 스타일 통제 가능성을 중심으로 도구와 결과물을 평가한다. 플레이어 평가에서는 AI 생성 그래픽이 게임의 몰입감, 품질 인식, 브랜드, IP에 대한 인상에 어떤 영향을 미치는지, 인간 제작 자산과 비교하여 선호도와 신뢰도가 어떻게 달라지는지 등을 분석한다.

6. 게임 아티스트 관점의 생성형 AI 수용과 협업 구조

생성형 AI 도입은 기술적 가능성뿐 아니라 게임 아티스트의 역할, 교육, 윤리, 노동 구조와 밀접하게 연결된다. 인터뷰 및 설문 기반 연구에 따르면, 많은 아티스트는 생성형 AI를 초기 단계에서 유용한 도구로 인식하고 있다. 특히, 레퍼런스 이미지 생성, 무드보드 생성, 아이디어 스케치, 프로토타입용 플레이스홀더 제작에서 생성형 모델은 시각적 탐색 범위를 넓히고, 다양한 스타일과 구성을 빠르게 비교할 수 있게 해준다 [14].

반면, 최종 인게임 에셋 제작 단계에서는 스타일 일관성 유지, 저작권, 품질 통제의 어려움으로 인해 보수적인 태도를 유지하는 경우가 많다. 학습 데이터 출처가 불분명한 모델을 사용할 경우, 기존 게임의 아트 스타일을 무단 차용하거나, 특정 작가의 고유한 스타일을 그대로 모사하는 결과가 나올 수 있다는 우려도 제기된다.

생성형 AI를 효과적인 활용을 위해서는 전통적인 드로잉, 디자인 역량과 더불어, 생성형 모델의 한계와 편향을 이해하고 프롬프트 엔지니어링, 제어 파라미터 조정, 후편집을 통해 원하는 결과를 끌어내는 능력이 필요하다. 생성형 AI에 과도한 의존은 디자인 고착과 기술 퇴화를 초래할 수 있으며, 비윤리적 이미지나 기능적으로 부적합한 에셋을 걸러내기 위해 비판적 시각이 필수적이다.

이러한 맥락에서 생성형 AI는 게임 아티스트를 대체하는 기술이 아니라, 반복 작업을 줄이고 탐

색 공간을 확장하는 창의적 보조 도구로 이해하는 것이 타당하다. 향후에는 co-pilot 모델, mixed-initiative 시스템 등 인간-AI 협업 패턴에 대한 체계적인 연구와 이에 맞춘 교육 커리큘럼 설계가 중요해질 것으로 예상된다.

7. 결론 및 향후 연구 과제

본 논문은 생성형 인공지능을 활용한 2D 게임 그래픽 에셋 제작 연구를 대상으로, 이론적 배경, 핵심 기술, 제작 파이프라인, 평가 지표, 인간-AI 협업 구조를 중심으로 최근 동향을 정리하였다. 생성적 적대 신경망과 이미지-이미지 변환 모델은 아이콘, 픽셀 아트, 이펙트 스프라이트 생성에서 의미 있는 성과를 보여주고 있으며, 확산 모델은 스프라이트 시트와 애니메이션과 같은 복잡한 2D 에셋 생성의 가능성을 크게 확장하고 있다. 또한, 딥러닝 보조 채색 및 협업 도구는 반복 작업을 줄이고 아티스트의 생산성을 높이는 실질적인 수단으로 자리 잡아 가는 중이다.

동시에, 도메인 일반화, 프레임 일관성, 타일링 지원, 팔레트 제약, 저작권 및 데이터셋 출처 문제, 아티스트 역할 변화 등 해결해야 할 과제도 적지 않다. 특히 2D 게임 그래픽 에셋의 고유한 특성을 반영한 공개 데이터셋과 벤치마크, 도메인 특화 평가 지표, 게임 엔진 및 튜체인과의 긴밀한 통합, 사용자와 플레이어 평가를 포함한 다층적 검증이 필요하다.

향후 연구에서는 첫째, 소량 데이터에서도 안정적으로 학습 가능한 2D 게임 특화 생성 모델, 둘째, 타일링, 레이어 분리, 팔레트 양자화, PBR 텍스처 변환 등 자동 후처리 모듈, 셋째, 2D 게임 그래픽 에셋 전용 공개 벤치마크와 평가 프로토콜, 마지막으로, 인간-AI 협업 워크플로와 교육 모델에 대한 실증 연구가 중요한 방향이 될 것이다.

종합하면, 생성형 AI는 2D 게임 그래픽 에셋 제작의 효율성과 표현력을 동시에 확장할 수 있는 강력한 기술이지만, 그 잠재력을 온전히 실현하기 위해서는 기술적 완성도, 객관적 평가 체계, 인간 요소를 아우르는 통합적 접근과 책임 있는 사용이 필수적이다.

References

- [1] K. Fukaya, D. Daylamani-Zad, H. W. Agius, "Intelligent generation of graphical game assets: A conceptual framework and systematic review of the state of the art", *ACM Computing Surveys*, vol. 57, no. 5, pp. 1-38, January 2025, doi: 10.1145/3708499.
- [2] K. Fukaya, D. Daylamani-Zad, H. W. Agius, "Evaluation metrics for intelligent generation of graphical game assets: A systematic survey-based framework", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 46, no. 12, pp. 7998-8017, May 2024, doi: 10.1109/TPAMI.2024.3398998.
- [3] R. Karp, Z. Swiderska-Chadaj, "Automatic generation of graphical game assets using GAN", 2021 7th International Conference on Computer Technology Applications (ICCTA 2021), Vienna, Austria, July 13-15,

- 2021, pp. 7-12, doi: 10.1145/3477911.3477913.
- [4] X. Liu, "Gans used to generate 2D game resources", International Conference on Computer Science, Engineering and Information Technology (CSEIT 2025), July 19-20, 2025, Toronto, Canada, pp. 1-9, doi: 10.1051/itmconf/20257804002.
- [5] S. Hong, S. Kim, S. Kang, "Game sprite generator using a multi discriminator GAN", KSII Transactions on Internet and Information Systems, vol. 13, no. 8, August 2019, pp. 4255-4269, doi: 10.3837/tiis.2019.08.025.
- [6] Y. R. Serpa, M. A. F. Rodrigues, "Towards machine-learning assisted asset generation for games: A study on pixel art sprite sheets", 2019 18th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames), Rio de Janeiro, Brazil, 28-31 October, 2019, pp. 182-191, doi: 10.1109/SBGames.2019.00032.
- [7] J. Kim, K. Jin, S. Jang, S. Kang, Y. Kim, "Game effect sprite generation with minimal data via conditional GAN", Expert Syst. Appl., vol. 211, January 2023, pp. 118491, doi: 10.1016/j.eswa.2022.118491.
- [8] F. Coutinho, L. Chaimowicz, "Pixel art character generation as an image-to-image translation problem using GANs", Graph. Models, vol. 132, April 2024, pp. 101213, doi: 10.1016/j.gmod.2024.101213.
- [9] F. Coutinho, L. Chaimowicz, "Generating Pixel Art Character Sprites using GANs," 21st Brazilian Symposium on Computer Games and Digital Entertainment (SBGames 2022), Natal, Brazil, October 24-27, 2022, pp. 61-66, doi: 10.48550/arXiv.2208.06413.
- [10] F. Coutinho, L. Chaimowicz, "A missing data imputation GAN for character sprite generation", 23rd Brazilian Symposium on Computer Games and Digital Entertainment (SBGames 2024), Manaus, Brazil, September 30-October 3, 2024, pp. 436-455, doi: 10.5753/sbgames.2024.241116.
- [11] C. A. Hsieh, J. Zhang, A. Yan, "Sprite sheet diffusion: Generate game character for animation", arXiv preprint arXiv:2412.03685, March 2025, pp. 1-31, doi: 10.48550/arXiv.2412.03685.
- [12] K. Fukaya, "User Centred Artificial Intelligence for Game Design and Development with the GAGeTx framework: Graphical Asset Generation and Transformation", PhD thesis, Brunel Design School, Brunel University London, United Kingdom, 2025. [Online]. Available: <https://bura.brunel.ac.uk/handle/2438/30775>.
- [13] Y. R. Serpa, M. A. F. Rodrigues, "Human and machine collaboration for painting game assets with deep learning", Entertainment Computing, vol. 43, June 2022, pp. 100497, doi: 10.1016/j.entcom.2022.100497.
- [14] J. Aho, "Game artists and generative AI: Utilizing generative AI in a creative, thoughtful, and skill enhancing way", Master's thesis, Information and Communications Technology, Turku University of Applied Sciences, Turku, Finland, 2025. [Online]. Available: <https://urn.fi/URN:NBN:fi:amk-202504277850>.