

논문 2023-18-30

GAN을 이용한 게임 캐릭터 이미지 생성 (Game Character Image Generation Using GAN)

김 정 기, 정 명 준, 차 경 애*
(Jeoung-Gi Kim, Myoung-Jun Jung, Kyung-Ae Cha)

Abstract : GAN (Generative Adversarial Networks) creates highly sophisticated counterfeit products by learning real images or text and inferring commonalities. Therefore, it can be useful in fields that require the creation of large-scale images or graphics. In this paper, we implement GAN-based game character creation AI that can dramatically reduce illustration design work costs by providing expansion and automation of game character image creation. This is very efficient in game development as it allows mass production of various character images at low cost.

Keywords : GAN (Generative Adversarial Networks), StyleGAN2-ADA, Diffusion model, Game character image

I. 서 론

인공지능 기술은 컴퓨팅과 연관된 영역이 아니더라도 그 활용성이 증대되고 있다. 그중에서 GAN (Generative Adversarial Networks) [1, 2]은 학습된 데이터를 기반으로 영상, 이미지, 텍스트 등을 새롭게 생성해 내거나 변환하는 기술이다. 특히 GAN은 비지도 학습의 일종이므로 사람 얼굴, 동물, 풍경 등 어떤 형상이라도 용도에 따라서 학습 데이터를 구축하면 변환된 결과물을 도출할 수 있는 알고리즘이다. 따라서 대용량의 이미지나 그래픽의 생성을 요구하는 분야에서 유용하게 활용할 수 있다. 또한, GAN을 활용한 기술의 응용은 사용자 의도를 반영하여 새로운 생성물을 출력해냄으로써, 디자인과 같은 분야에서 지능적 협업이 가능한 도구로 이용할 수 있다 [3].

본 논문에서는 게임 개발 과정에서의 캐릭터 이미지 생성 기능 확장과 자동화 등을 제공하여 일러스트 디자인 작업 비용을 의미있게 감소할 수 있는 GAN 기반의 게임 캐릭터 생성 AI를 구현한다.

게임 개발에 사용되는 캐릭터 이미지는 기획 내용을 바탕으로 일러스트 디자이너의 작업으로 이루어지는 것이 일반적이다. 이때 기획된 캐릭터의 특징을 일일이 고려한 이미지 제작 작업이 필요하므로 인력, 시간, 비용이 상당히 소요된다. 이러한 작업은 GAN의 디자인 의도를 반영한 학습과 더불어 출력의 혼합과 변형을 통한 디자인 영감의 확장도 제공할 수 있는 AI 도구의 지원으로 효율성을 높일 수 있다.

본 논문은 image to image translation을 수행하는 GAN 알고리즘인 StyleGAN2-ADA [4-7]을 활용하여 게임 캐릭터 이미지 GAN 모델을 생성하였다.

StyleGAN2-ADA는 학습 데이터의 스타일을 다양화하여

재생산하는 특징을 가지고 있다. 따라서 여러 종류의 스타일을 가진 이미지나 그래픽을 요구하는 게임 캐릭터 생성 분야에서 유용하게 활용할 수 있다.

또한 생성한 이미지의 품질 (화질) 향상 및 활용도를 높이기 위하여 Latent Diffusion 모델인 Stable Diffusion [6, 7]을 결합하였다. 최종 캐릭터 이미지의 특징을 텍스트 입력 등으로 반영할 수 있기 때문에 사용자와 상호작용 기능을 제공할 수 있다.

이를 활용하여 다양하고 많은 수의 캐릭터 이미지를 적은 비용으로 생산할 수 있기 때문에 게임 개발 등의 일러스트 작업 비중이 높은 영역에 매우 효율적이다. 본 논문에서 구현한 게임 캐릭터 이미지 생성 AI 시스템을 통해서 약 60여 개의 고품질의 캐릭터 이미지를 48시간에서 72시간 내에 제작하고 게임 개발에 직접 활용하여 그 효율성을 확인하였다.

본 논문의 구성은 다음과 같다. 2장에서 관련 연구를 설명하고 3장에서 학습 데이터 구축과 모델 생성의 과정을 기술한다. 그리고 4장에서 실험 결과를 보이고 5장에서 결론을 맺는다.

II. 관련 연구

1. StyleGAN2-ADA

GAN은 생성자 (Generator)와 판별자 (Discriminator)라는 두 종류의 신경망으로 구성된 알고리즘이며, 생성자가 이미지를 새롭게 생성하고 판별자는 그 진위를 판별하여, 고품질의 이미지를 출력하는 원리로 동작한다. 그 중 StyleGAN2-ADA [4-7]는 적응형 판별자 증가 기법인 ADA (Adaptive Discriminator Augmentation Mechanism)를 도입함으로써 판별자를 보강하여 StyleGAN [8]의 단점을 해결한 향상된 모델이다. 즉 학습 데이터의 증강을 통해서 기존의 GAN 모델에 비해서 적은 이미지로도 학습 모델을 도출할 수 있다.

*Corresponding Author (chaka@daegu.ac.kr)
Received: Jul. 3, 2023, Revised: Aug. 11, 2023, Accepted: Aug. 25, 2023.
J. G. Kim: Daegu University (Undergraduate Student)
M. J. Jung: Daegu University (Undergraduate Student)
K. A. Cha: Daegu University (Prof.)

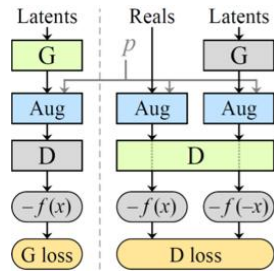


그림 1. StyleGAN2-ADA의 G/D 플로우차트 [7]
 Fig. 1. StyleGAN2-ADA stochastic discriminator augmentations [7]

그림 1은 StyleGAN2-ADA의 동작 플로우차트이다. 이미지 증강의 핵심 기능인 ADA는 증강 확률 (p)의 동적 조절에 의해서 학습 데이터가 다양하게 변형되며 생성자와 판별자는 증강 이미지를 바탕으로 학습하도록 설계되었다 [7]. 증강 확률 (p)은 0에서 1의 값이며 1에 가까울수록 증강을 많이 한다. 이미지 증강 타입에는 자르기 (cutout), 픽셀 블리팅 (blit), 기하학적 변환 (geom), 색상 변환 (color), 이미지 공간 필터링 (filter), 노이즈 추가 (noise) 등이 있다.

일반적으로 고품질의 GAN 모델을 학습시키기 위해서 보통 10만 개에서 100만 개의 이미지가 필요하다 [8]. 그러나 StyleGAN2-ADA 모델은 이와 같은 증강 기법을 이용하기 때문에 본 논문에서는 약 2만여 개의 이미지를 학습 데이터로 훈련하여 다채로운 게임 캐릭터 이미지를 출력할 수 있었다.

2. Stable Diffusion

Stable Diffusion [6]은 text to image 및 image to image 작업에 사용되는 잠재 확산 (Latent Diffusion) 모델을 이용한 고해상도 이미지를 생성하는 모델이다.

이는 텍스트 프롬프트를 통해서 제작 의도를 직접 반영할 수 있기 때문에 단시간에 캐릭터의 특징을 변형하여 그 출력을 관찰하여 새로운 의도와 영감으로 상호작용 가능한 이미지 생성 기능을 제공할 수 있다. 또한 Stable Diffusion을 통해서 StyleGAN2-ADA 학습 모델이 생성한 이미지를 고화질로 최종 출력할 수 있다.

3. 게임 캐릭터 이미지 생성 활용 예

GAN 모델을 활용하여 게임 캐릭터 이미지를 생성하는 사례로는 3D 얼굴의 각 측면을 학습하고 2D의 캐릭터 얼굴 이미지에 해당하는 여러 각도의 측면 이미지를 생성하는 안면 회전 기술에 대한 연구 [9]가 있다. 즉, GAN을 이용하여 3D 캐릭터 얼굴의 여러 각도에서 촬영한 이미지를 학습하고 정면 얼굴을 입력하여 다른 각도의 일러스트를 출력하는 것이다. GAN의 게임 일러스트 생성 기술의 활용 측면에서 가능성을 보여주었으나, 얼굴의 3차원 변형을 대상으로 한다. 따라서 본 논문과 같이 실제 게임 제작에 활용하는 캐릭터 이미지를 만들어 내기 위해서 게임 기획에 부합되는 특성을 학습하여 이미지를 생성하는 연구와는 차이점이 있다.



그림 2. 학습 이미지의 예
 Fig. 2. Example of Training Images

III. 학습 데이터 구축과 생성 AI 모델 제작

1. 학습 데이터 구축

학습 데이터는 저작권이 없거나 수정, 배포가 가능한 저작권 마크가 있는 사이트인 pixabay [10], charat [11], freepik [12], irasutoya [13], vonvon [14]에서 약 2만 장의 캐릭터 이미지를 수집하였다 [15]. 기획 의도에 적합한 학습 이미지의 수집은 매우 어려우나 StyleGAN2-ADA 모델의 장점인 기존 GAN 학습에 필요한 이미지 양 대비 5분의 1에서 50분의 1의 이미지 개수 [7, 15]인 2만여 개로 학습이 가능하였다.

학습 이미지는 게임 기획에 따라서 그에 부합되는 형태를 수집하여야 하므로, 본 논문에서는 선택지 게임 장르를 기획하고 수집 대상 이미지를 명세화하였다. 게임의 스토리는 주인공이 화술을 통해서 타락한 용사를 무찌르는 이야기를 담고 있어, 맵마다 캐릭터와 화술 및 선택지를 표현하도록 제작되어야 한다. 캐릭터와의 대화 흐름에 의해서 엔딩이 변화하기 때문에 쉽게 엔딩을 볼 수 없도록 많은 캐릭터가 필요한 기획이다.

캐릭터의 명세는 그림 2와 같이 정면의 서 있는 모습인 전신 사이즈이며, 훈련을 위해서 수집 후 정제된 512 X 512 픽셀 크기의 RGB (24bit) 색상의 이미지이다. 또한 배경이나 악세사리 등을 삭제하는 전처리를 수행하여 초기 학습을 위한 2만 7천 장의 이미지를 학습 데이터로 구축하였다.

2. 게임 캐릭터 생성 AI 모델의 구성

본 논문에서 구현한 게임 캐릭터 이미지 생성 AI의 구조는 그림 3과 같다. 게임 기획 의도에 부합되는 이미지를 수집하여 정제한 학습 데이터를 훈련하여 StyleGAN2-ADA 모델을 생성한다. 즉, 최종 생성되는 이미지가 실제 게임 제작에 활용할 수 있는 형태로 출력하도록 모델을 학습시킨다.

그리고, 구축된 학습 모델에서 출력된 이미지를 디자인 의도를 반영하는 텍스트와 화풍을 입력하여 Stable Diffusion을

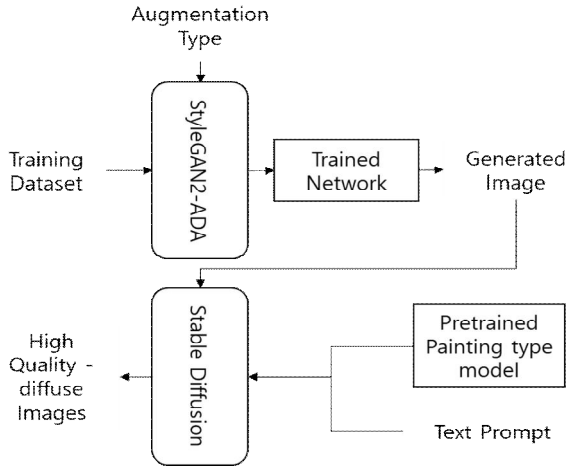


그림 3. 캐릭터 이미지 생성 AI 구성도
Fig. 3. Character image generation AI generation diagram

학습시킴으로써 최종적으로 게임 개발에 사용할 고품질의 캐릭터 이미지를 출력하는 구조이다. 최종 출력 이미지는 학습 모델을 통해서 AI가 변형 확산한 이미지로 초기 학습 데이터를 기반으로 창의적 형태를 가진다.

이와 같이 학습 이미지 증강을 위한 ADA 타입을 여러 가지 조합으로 적용하고 생성된 이미지에 사전 학습된 화풍 모델을 적용하여 기존의 디자이너가 작업 의도를 반영하는 일러스트 작업과 같은 도구가 제공되도록 구현하였다.

3. StyleGAN2-ADA 학습 모델 생성

StyleGAN2-ADA는 생성 AI이므로 전체 훈련 이미지를 학습하고 그 스타일을 변형 및 혼합하여 새로운 이미지를 출력한다. 따라서 초기에 구축한 학습 데이터 2만 7천 장을 대상으로 훈련을 진행하였다. 이때, 판별자가 한 번에 몇 장의 이미지를 판단할지를 설정하는 값인 kimg 단위로 학습 횟수 [16]를 나타내며, 해당 값에 도달할 때까지 훈련이 진행된다. 1kimg 당 1,000회씩 학습하며, 생성 이미지는 100 kimg (10만 회) 단위로 출력한다.

최종 학습 모델을 도출하기 위해서 출력된 이미지를 점검하고 캐릭터 명세에서 벗어나는 이미지들은 다시 정제하여 훈련하는 과정을 3회 반복하였다. 3회 훈련의 결과가 게임 개발에 사용할 수 있는 수준의 생성 이미지를 보여주었기 때문이다.

표 1은 StyleGAN2-ADA 모델을 훈련하는 과정에서 학습 이미지의 수량과 적용한 이미지 증강 타입, 하이퍼파라미터 등을 보이고 있다. 세부 사항에서 ada_target은 ADA의 증강 확률이며 lrate는 learning rate, snap은 출력 단위를 나타내는 값이다.

학습 모델을 훈련하기 위한 컴퓨팅 환경은 표 2와 같이 GPU 환경에서 파이썬 및 CUDA 엔진/파이토치를 사용하여 구현하였다.

첫 번째 학습 및 출력에서 학습 횟수는 1000kimg (100만 회), ADA 방식은 픽셀 블리팅 (blit), 기하학적 변환 (geom),

표 1. StyleGAN2-ADA 학습 파라미터
Table 1. StyleGAN2-ADA learning parameters

Data set	27000	24000	21000
Training amount	1000kimg	1000kimg	4000kimg
Augmentation type	blit geom color	blit geom color	cutout blit geom color fliter noise
Image Size	512 X 512		
ada_target	0.6		
lrate	0.002		
snap	100		
time	about 36 hours	about 30 hours	about 24 hours

표 2. StyleGAN2-ADA 모델 훈련 컴퓨팅 환경
Table 2. StyleGAN2-ADA model training computing environment

CPU	11th Intel (R) i9-11900k
RAM	64.0GB
GPU	NVIDIA RTX 3080Ti
Anaconda Python Ver.	3.9.12
CUDA Engine Ver.	CUDA 11.3
Pytorch Ver.	11.3

색상 변환 (color)을 적용하였다. 모델이 캐릭터 이미지를 출력하는 훈련 시간은 약 36시간이 소요되었다.

그림 4는 1회 학습 결과로 나타나는 이미지의 예로 왜곡 현상이 상당히 포함되어 있다.

두 번째 학습 및 출력 역시 1000kimg 학습 및 첫 번째 학습 과정과 마찬가지로 픽셀 블리팅 (blit), 기하학적 변환 (geom), 색상 변환 (color)의 세 가지 ADA 방식을 사용하였다. 이미 학습에 의해서 출력된 이미지의 일부를 정제하고 불필요한 이미지를 제외한 2만 4천 장의 이미지를 입력하였으며 훈련 시간은 약 30시간이 소요되었다.

출력된 이미지의 예로 그림 5에서 보이는 것처럼 3D와 2D가 겹쳐서 두 이미지를 구분하는 경계선이 무너져 사람의 형태이지만 얼굴이나 몸통의 모습이 붕괴하는 현상을 보이는 이미지들이 나타났다.

세 번째 학습 및 출력에서는 학습량 4000kimg을 사용했고 ADA 방식은 픽셀 블리팅 (blit), 기하학적 변환 (geom), 색상 변환 (color)뿐만 아니라 자르기 (cutout), 이미지 공간 필터링 (filter), 노이즈 추가 (noise)을 적용하였다. 이는 이전 학습 과정이 있었기 때문에 학습량을 늘리고 ADA를 추가하더라도 학습 시간 소요가 감소될 것이라고 예상되어, 학습 시 사용하는 옵션을 증가시킨 것이다. 또한 캐릭터 명세의 범위를 고려하여 일부가 제외된 2만 1천 장의 캐릭터 이미지를 훈련하였다. 학습 시간은 약 24시간이 소요되었다.

그 결과, 그림 6과 같이 게임에 접목할 수 있는 캐릭터 형태인, 정면의 서 있는 사람 이미지이면서 게임의 스토리



그림 4. StyleGAN2-ADA 출력 이미지의 예 (1)
Fig. 4. Example of StyleGAN2-ADA output images (1)



그림 5. StyleGAN2-ADA 출력 이미지의 예 (2)
Fig. 5. Example of StyleGAN2-ADA output images (2)



그림 6. StyleGAN2-ADA 출력 이미지의 예 (3)
Fig. 6. Example of StyleGAN2-ADA output images (3)


와 배경에 부합되는 캐릭터 이미지들이 출력되었다. 특히 ADA 기법인 증강 타입을 추가로 사용하였기에 다양한 스타일의 캐릭터가 생성되었으며, 얼굴 형태와 이목구비의 위치가 정확하게 표현되었다. 그리고 초기 학습 이미지와 같은 형태이지만 스타일이 구분되는 캐릭터 이미지로 변형 생성되어서 AI 모델이 출력하는 창의적 이미지를 활용할 수 있었다.

IV. 캐릭터 이미지 생성 실험 및 분석

1. StyleGAN2-ADA 학습 결과


학습 과정에서 초기의 노이즈와 이미지 생성 결과는 그림 7과 그림 8에서 나타낸다. 훈련이 진행되면서 생성되는 이미지의 중간 과정과 최종적으로 4000king의 학습을 거쳐 생성된 이미지는 그림 8의 fake4000 이미지와 같다. 학습 모델에서 생성한 이미지는 캐릭터 이미지로 활용 가능한 형태임을 볼 수 있다.

GAN 모델은 생성자와 판별자가 서로 경쟁하면서 Loss 값이 변화된다 [17]. StyleGAN2-ADA의 최종 학습 모델의



fake0000


그림 7. 초기의 랜덤 노이즈 (fake0000)
Fig. 7. Initial Random Noise (fake0000)



fake0100



fake2000



fake4000

그림 8. 이미지 생성 과정의 결과
Fig. 8. Example images generated during training

Loss 그래프는 그림 9와 같이 판별자와 생성자의 Loss 값이 초기 학습 이후부터 일정 범위 내에서 서로 증감이 일어나며 적대적인 학습이 경쟁적으로 진행됨을 볼 수 있다. 즉,




그림 9. 판별자와 생성자의 Loss
Fig. 9. Loss Graph for D/G

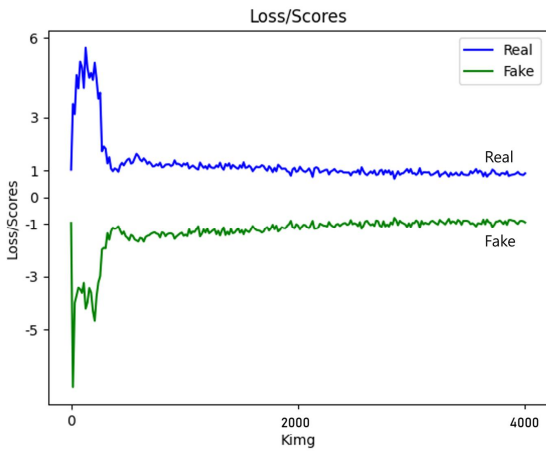


그림 10. 판별자의 탐지 점수
Fig. 10. score/fake and score/real Graph

두 그래프에서 학습 초기에서의 진동이 생성자와 판별자가 서로 대칭적인 수치 변화를 보이고 있으며, 학습이 진행되면서 어느 정도 일정한 값에 수렴하고 있다.

판별자의 탐지 점수는 그림 10의 그래프와 같다. fake score의 값이 낮은 수치를 보이고 real score의 곡선이 더 높은 값을 유지하여 진짜와 가짜 이미지의 판별이 잘 이루어지고 있음을 알 수 있다.

표 3. Stable Diffusion 실행 환경
Table 3. Stable Diffusion execution environment

CPU	Intel (R) Core (TM) i3-10100F
RAM	32.0GB
GPU	NVIDIA RTX 3060Ti
Pytorch Ver.	1.13.1



그림 11. 스테이블 디퓨전 웹UI
Fig. 11. Stable Diffusion WebUI

2. Stable Diffusion 모델 적용

StyleGAN2-ADA에 생성한 캐릭터 이미지의 실 사용성을 높이기 위해서 Stable Diffusion WebUI [18]를 설치하여 고 해상도 이미지로 재생성한다. Stable Diffusion은 표 3의 환경에서 실행하였다. StyleGAN2-ADA에서 출력되는 이미지를 고해상도로 재생성할 수 있는 웹 기반의 Stable Diffusion은 StyleGAN2-ADA 모델의 학습 환경과는 별개로 진행될 수 있으므로 서로 다른 컴퓨팅 환경을 사용하였다.

그림 11은 설치한 Stable Diffusion WebUI의 실행 화면이다. 확산 모델을 수행하기 위해서 각종 옵션을 설정할 수 있으며, text to image 및 image to image transformation을 수행한다.

Stable Diffusion의 텍스트 프롬프트를 통해서 이미지 변환에 대한 긍정적 의도와 부정적 의도를 입력할 수 있다. 긍정적인 프롬프트에 적힌 텍스트는 변형을 시도하라고 요구하는 것이며, 부정적인 프롬프트는 수행을 원하지 않는 요구사항이다.

화풍 [19]과 옵션을 설정하고 이미지 해상도를 변화시켜 실행 및 출력했을 경우 표 4와 같이 시간이 소요가 되었다. 설정된 옵션으로 Checkpoint는 AbyssOrangeMix2, Sampling method은 DPM++ SDE karras 방식, Sampling Steps는 20으로 지정하였다.

이미지 해상도를 다양하게 생성한 것은 게임 개발에 사용할 수 있는 고해상도 이미지 출력 결과를 관찰하기 위해서

표 4. Stable Diffusion의 소요시간
Table 4. Stable Diffusion time required

Image size	Complete time
512X768	05.46s
768X768	12.55s
768X1024	16.94s
1024X1024	32.66s
1024X1280	47.81s
1280X1280	1m 13.53s
1280X1440	1m 32.75s
1440X1440	Error



그림 12. 최종 생성된 고품질 이미지의 예
Fig. 12. Examples of high quality diffuse images

이다. 1440 X 1440부터는 GPU 성능의 한계로 이미지 생성이 불가능한 것으로 나왔다.

그림 12는 체크포인트 (화풍 모델)와 텍스트 프롬프트의 내용 등을 변경하여 입력 이미지에 대한 다양한 변형 결과를 볼 수 있는 예이다. 하나의 이미지를 통해서 다른 캐릭터를 그린 것처럼 다양한 형태로 생성할 수 있다 [19].

3. 생성 캐릭터 이미지의 게임 개발에의 적용 및 분석

앞서 기획한 선택지 게임을 개발하면서 본 논문의 게임 캐릭터 생성 AI를 통해서 캐릭터 이미지를 사용하였다. 약 60여 개의 캐릭터 이미지를 출력하여 추가 작업이 없이 게임 일러스트로 사용하여 개발 소요 시간과 비용을 획기적으로 줄일 수 있었다.

그림 13은 개발한 선택지 게임의 여러 장면이며 구현한 생성 AI에 의해서 출력된 캐릭터 이미지의 활용 결과를 보이고 있다. 여러 맵을 통해서 장면 이동이 일어나며 각 맵에서 고화질의 서로 다른 특징을 가진 캐릭터가 투입되어 게임의 완성도를 높였다.

일러스트 디자이너에 의한 작업 비용을 알아보기 위해서 프리랜서마켓 [20]에서 캐릭터 명세 1장의 이미지 제작 시 비용과 시간을 조사하였다. 소요 시간은 평균 20일 정도였으며 비용은 약 오만원에서 백팔십만원으로 나타났다 (조사 시점은 23년 8월).




그림 13. 생성한 캐릭터 이미지를 활용한 게임 개발 장면
Fig. 13. Example of Game scene using the created character image

표 5. 디자인 외주와 생성 AI의 비용 비교 (이미지 1장 기준)
Table 5. Cost Comparison of Design Outsourcing and Our Generative AI (based on 1 image) (Benchmark on Aug. 2023)

	Design Outsourcing	Our Generative AI
time	average 20 days (including quality)	2~3 days
money cost	average KRW 900,000	none
feedback	average 4~5 days (including quality)	immediately
deadline	no time guarantee	guaranteed deadline

이는 확정될 수 없는 비용이며 일러스트의 품질과 용도 등에 따라서 디자이너와의 의사소통을 통해서 비용이 결정된다.

이를 보아 실제 디자이너와 같은 인력이 생산하는 캐릭터 이미지 작업에는 상당한 시간과 비용이 요구됨을 알 수 있다. 표 5와 같이 본 논문에서 구현한 게임 캐릭터 생성 AI와 비교하여 매우 큰 차이를 보일 것이다. 따라서 수많은 일러스트 작업이 필요한 게임 개발 분야에서 생성 AI의 활용은 시간, 인력, 비용을 매우 효과적으로 감소한다.

생성 AI의 성능은 일반적으로 정성적으로 평가한다 [21, 22]. 실제 일러스트 제작에 적용한 기존 연구로는 웹툰 배경 그래픽 작업을 생성하는 연구 [21]가 있다. 웹툰 제작 분야도 게임 제작과 유사하게 인력과 비용이 요구되는 일러스트 수작업이 필요하다. 이 연구에서는 학습 모델이 생성한 이미지와 실제 웹툰 배경 이미지와의 유사성을 비교하는 설문으로 정성적 평가를 하였다.

본 논문에서는 게임의 설계에서 도출된 캐릭터의 특성을 반영하는 학습 데이터로 모델을 학습시키고 출력하는 이미지를 게임 제작에 사용하는 데에 무리가 없었으며 구현된 게임을 플레이하는 시연에서 캐릭터의 부조화성에 대한 피드백이 없었다. 이로써 수작업이 요구되는 창의적 제작 분야에 AI의 효용성을 알 수 있다.

V. 결론

본 논문에서는 게임 개발에 사용되는 대량의 캐릭터 이미지를 자동 생성함으로써 비용과 시간 등을 절감하는 생성 AI 모델을 구축하였다. 사용한 모델은 StyleGAN2-ADA와 Stable Diffusion이며 다양하고 창의적인 이미지를 만들어냄으로써 실제 게임 개발에 활용하였다. 또한 디자이너의 작업 범위를 최대한 반영하는 AI 모델 생성이 가능하도록 실험에서 학습 데이터 정제와 활용성을 검증하였다. 이를 통해서 기존 디자이너의 작업에 대부분 의존되어 있는 게임 캐릭터 이미지의 창의적 자동 생성이 가능함을 보였다.

향후 시시각각 발전되고 있는 GAN 모델을 적극 활용하여 보다 향상된 성능으로 구현할 예정이다.

References

[1] A. Radford, L. Metz, C. Soumith, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," Computer Science, Machine Learning, arXiv preprint arXiv:1511.06434, 2015.

[2] K. Wang, C. Gou, Y. Duan, Y. Lin, X. Zheng, F. Wang, "Generative Adversarial Networks: Introduction and Outlook," IEEE - CAA Journal of Automatica Sinica, Vol. 4, No. 4, pp. 588 - 598, 2017.

[3] M. Cui, M. Kim, S. Choi, S. Lee, "The Usage and Impact of GAN in Graphic Design," Archives of Design Research, Vol. 35, No. 4 pp. 285-307, 2022 (in Korean).

[4] C. Liao, M. Sawayama, B. Xiao, "A Perceptual Evaluation of the StyleGAN2-ADA Generated Images of Translucent Objects," Journal of Vision, Vol. 22, No. 14, pp. 3642-3642, 2022.

[5] Y. Lu, "Style-based Image Manipulation Using the StyleGAN2-Ada Architecture," Proceedings of 4th International Conference on Computing and Data Science, pp. 29-37, 2022.

[6] R. Rombach, A. Blattmann, D. Lorenz, P. Esser, B.

Ommer, "High-Resolution Image Synthesis with Latent Diffusion Models," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 10684-10695, 2022.

[7] T. Karras, M. Aittala, J. Hellsten, S. Laine, J. Lehtinen, T. Aila, "Training Generative Adversarial Networks with Limited Data," Advances in Neural Information Processing Systems, 33, pp. 12104 - 12114, 2020.

[8] T. Karras, S. Laine, T. Aila, "A Style-based Generator Architecture for Generative Adversarial Networks," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 4401-4410, 2019.

[9] H. D. Kim, J. D. Han, H. K. Yang, K. H. Min, "A GAN-based Face Rotation Technique Using 3D Face Model for Game Characters," Journal of Korea Game Society, Vol. 21, No. 3, pp. 13-23, 2021 (in Korean).

[10] <https://pixabay.com/ko>

[11] <https://charat.me>

[12] <https://www.freepik.com>

[13] <https://www.irasutoya.com>

[14] <https://kr.vonvon.me/quiz/604>

[15] J. Kim, M. Jeong, S. Lee, J. Jeong, S. Park, K. Cha "Game Character Image Creation AI," Proceedings of Spring Conference on Korea Multimedia Society, Vol 26, No. 1, pp. 24-27, 2023 (in Korean).

[16] <https://github.com/NVlabs/stylegan2-ada-pytorch>

[17] D. A. Talib, A. A. Abed, "Real-Time Deepfake Image Generation Based on Stylegan2-ADA," Revue d'Intelligence Artificielle, Vol. 37, No. 2, pp. 397-405, 2023.

[18] <https://github.com/AUTOMATIC1111/stable-diffusion-webui>

[19] <https://huggingface.co>

[20] <https://kmong.com/>

[21] S. K. Oh, J. Y. Kang, "A Study on Webtoon Background Image Generation Using CartoonGAN Algorithm," Korea BigData Society, Vol. 7, No. 1, pp. 173-185, 2022.

[22] S. Hicsonmeza, N. Samet, E. Akbas, P. Duygulu, "Ganilla: Generative Adversarial Networks for Image to Illustration Translation," Image and Vision Computing, Elsevier, Vol. 95, 103886, 2020.

Jeoung-Gi Kim (김 정 기)



2018~Department of Artificial Intelligence from Daegu University (Undergraduate Student)

Field of Interests: Game Programming, AI, Generative AI
Email: kik9982098@daum.net

Myoung-Jun Jung (정 명 준)

2018~Department of Artificial Intelligence
from Daegu University (Undergraduate
Student)

Field of Interests: Game Programming
Email: june991206@naver.com

Kyung-Ae Cha (차 경 애)

1996 Computer Science from Kyungpook
National University (B.S.)
1999 Computer Science from Kyungpook
National University (M.S.)
2003 Computer Science from Kyungpook
National University (Ph.D.)

2005~Department of Artificial Intelligence at Daegu University
(Professor)

Career:

2001~2003 Lecture Professor, Kyungpook National University

2004 Research Professor, ICU

Field of Interests: Generative AI, Multimedia System, AI
Convergence

Email: chaka@daegu.ac.kr