

StarGAN v2 기반 패션 아이템 다중 도메인 변환을 통한 이미지 생성 모델 구현

장혜림*, 손봉기*, 이재호^o

Implementation of the Image Generation Model for Fashion Item Multi Domain Transformation Based on StarGAN v2

Hyelim Jang*, Bong-Ki Son*, Jaeho Lee^o

요약

최근 다양한 GAN 모델이 개발되어 여러 분야에서 활용되고 있다. 본 논문에서는 패션 아이템에 대한 다중 세부 아이템 도메인 변환 시스템 구현을 위해 GAN 모델을 활용하고자 한다. 이를 위해 조건을 지정하여 원하는 도메인 스타일로 변환된 이미지를 생성할 수 있으며 객관적으로 검증된 StarGAN v2를 채택하여 실험 및 구현을 진행하였다. 데이터셋의 레이블링을 최소화하며 도메인에 따른 변환 결과를 정확히 도출할 수 있도록 세부 아이템별로 모델을 각각 생성하였다. 학습된 이미지 생성 모델을 활용하여 하나의 이미지에서 추출한 스타일을 다른 이미지에 합성하는 결과를 도출하였고, 모델들을 모두 활용하여 하나의 이미지에 대해 여러 도메인을 변환할 수 있도록 방안을 제시하였다. 각각의 도메인 변환 이미지 생성 모델에 대한 성능 평가를 위해 실제 이미지와 생성 이미지 사이의 유사도를 측정하고 평가 분석하였다.

Key Words : Object Detection, Mask R-CNN, Fashion Design Technique, GAN, StarGAN v2

ABSTRACT

Various GANs have been recently developed and are being used in wide application areas. In this paper, we intend to utilize the GAN model to implement a domain transformation system for multi-detailed item on fashion items. For the purpose, we experimented and implemented StarGAN v2, which is objectively verified model that can generate images converted to the desired domain style by specifying conditions. Models were created for each detailed item to minimize labeling of datasets and accurately derive transformation results according to domains. Using the pretrained image generation model, we derive a result of synthesizing styles extracted from one image into another image, and we present a plan to allow multiple domains to be transformed for one image by utilizing all of the models. Similarity between real and generated images is measured for performance evaluation of each domain transformed by image generation model.

* 본 연구는 한국연구재단을 통해 과학기술정보통신부의 기초연구사업으로부터 지원받아 수행됨(과제번호- NRF-2021R1A4A5028907).

• First Author : Duksung Women's University Department of IT Media, halley0323@duksung.ac.kr, 학생회원

o Corresponding Author : Duksung Women's University Department of Software, izeho@duksung.ac.kr, 종신회원

* Seowon University Department of Computer Science and Engineering, bksohn@seowon.ac.kr, 정회원

논문번호 : 202208-173-D-RN, Received August 11, 2022; Revised September 7, 2022; Accepted September 13, 2022

I. 서론

최근까지 Generative Adversarial Network (GAN)^[1]에 대한 연구는 최초로 발표된 2014년부터 현재까지 다방면으로 파생되어 활발히 진행되고 있다. 이미지를 생성하는 generator와 생성된 이미지의 진위여부를 판별하는 discriminator가 GAN의 핵심 구성요소이다. 실사와 유사한 이미지를 생성할 수 있기에 데이터셋 증강, 이미지 복구 등 활용도가 높으며 다양한 분야에서 주목받는다.

패션 분야에서도 이미지를 합성한 가상 피팅, 새로운 이미지 생성을 이용한 패션 아이템 디자인 등 여러 시스템 구현에 GAN 모델이 응용되고 있다. 본 논문에서는 선행 연구^[2]를 기반으로 지정한 조건에 맞는 패션 아이템 이미지 생성 및 스타일 변환을 위한 연구를 진행하였다. 개발 시스템은 패션 디자이너의 효율적인 디자인 프로세스와 의류 쇼핑몰의 이미지를 이용한 검색 구현에 거시적 목표를 두고 구현되었다.

패션 분야에서 아이템의 스타일 변환 이미지 생성을 위해 현재 많은 파생 모델이 개발되고 있으며, 여러 분야에서 주목받는 모델 중 대표적으로 StyleGAN^[3]이 있다. StyleGAN은 generator가 style transfer 가능한 구조로 형성되었으며, 네트워크의 각 계층에 스타일을 합성하여 이미지를 생성한다. 하지만 비지도 학습을 통해 생성되는 모델이고 네트워크가 스타일을 생성하므로, 직접 스타일을 학습하거나 원하는 조건의 스타일을 지닌 이미지 생성 관점에서 한계를 가진다.

이를 더 자세히 알 수 있는 사례로 패션 이미지 합성 모델인 ClothingGAN^[4]을 들 수 있다. StyleGAN 발전 모델 중 하나인 StyleGAN2-ADA를 학습한 ClothingGAN은 의류 이미지를 혼합 생성하는 동안 네트워크 구조나 스타일을 제어하여 몇 가지 지정된 속성에 대한 의복을 편집할 수 있는 기능을 제공한다. 하지만 지정해놓은 속성 변환만 가능하여 지정된 조건 기반 패션 스타일 변환 이미지 생성에는 어려움이 있다.

반면, StarGAN^[5]은 하나의 generator가 이미지와 도메인 정보를 모두 입력하여 유연하게 알맞은 타겟 도메인으로 변환된 이미지를 생성할 수 있도록 학습된다. 이렇게 생성된 generator는 여러 가지 도메인에 대해 변환할 수 있으며 원하는 도메인을 지정할 수 있기에 StarGAN 이미지 생성 모델을 채택하였다.

본 연구에서는 셔츠의 세부 아이템을 도메인으로 지정하여 다양한 셔츠 이미지의 생성과 특정 부분의

변환을 시도하였다. 비교적 최근에 발표된 StarGAN v2^[6]를 이미지 생성 모델로 학습하였고, 알맞은 학습 데이터셋을 구축하기 위해 이미지 내의 객체를 의미 있는 단위로 인식할 수 있는 Mask Region based Convolutional Neural Networks (Mask R-CNN)^[7] 기반으로 전처리를 진행하였다. 다양한 방식으로 데이터셋을 정제하기도 하고 여러 세부 아이템 도메인을 모두 변환할 수 있는 다중 이미지 생성 모델의 Frechet Inception Distance (FID) 를 측정하여 평가하고 분석하였다. 이를 통해 최종적으로 패션 스타일에 대한 다중 도메인 변환 시스템을 최적으로 구축하기 위한 실험 및 구현을 진행하였다.

II. 연구 배경

2.1 Mask R-CNN

Regions with Convolutional Neuron Networks (R-CNN)^[8] 이란 영역을 설정하고 CNN을 활용하여 object detection을 수행하는 신경망이다. Fast R-CNN^[9], Faster R-CNN^[10], Mask R-CNN 순으로 발전하였다. Fast R-CNN과 RPN을 결합한 모델이 Faster R-CNN이고, 단지 Object Detection을 위해 고안된 Faster R-CNN에 각 픽셀이 객체인지 아닌지를 masking 할 수 있는 새로운 branch를 추가한 모델이 Mask R-CNN이다.

이러한 Mask R-CNN은 객체의 위치를 찾아 박스를 표시하고 탐지된 객체를 분류하는 object detection 기술과 픽셀 단위로 객체를 예측하는 semantic segmentation 기술이 합쳐져 객체를 픽셀 단위로 탐지하여 의미 있는 단위로 분류할 수 있는 instance segmentation 기능을 갖는다.

그림 1은 상하의 데이터셋을 레이블링한 데이터셋으로 학습



그림 1. 상하의 데이터셋을 이용하여 학습한 Mask R-CNN 모델의 결과 (왼쪽 : 입력, 오른쪽 : 출력)
Fig. 1. Result of Mask R-CNN model learned from top and bottom datasets. (left : input, right : output)

된 Mask R-CNN 모델이 생성한 결과 이미지이다. 상의와 하의 객체의 위치를 찾고 경계선에 맞는 영역을 추출한 것과 알맞은 클래스를 예측한 결과를 확인할 수 있다.

2.2 StarGAN

StarGAN v1은 타겟 도메인과 이미지를 입력받아 조건에 맞게 변환된 이미지를 생성하는 generator와 이미지에 대한 진위 여부와 도메인 레이블에 대한 진위 여부를 판별하는 discriminator로 구성된다. StarGAN v2는 v1에 mapping network와 style encoder 모듈을 추가하여 각 도메인에 대해 동일한 변형만 가능했던 v1과 달리 특정한 스타일로 변환이 가능하도록 개선되었다. 한마디로 단일 style encoder와 단일 generator를 사용하여 다양한 도메인에 대한 style transfer를 할 수 있도록 발전된 것이다. 이러한 v2는 이미지의 스타일을 추출하여 다른 이미지에 반영한 새로운 이미지 생성도 가능하다. v2의 구조는 generator, mapping network, style encoder, discriminator 형태의 4가지로 구성되며, generator의 경우 기존 StarGAN 모델과 거의 유사하다. source 이미지와 함께 타겟 도메인에 대한 스타일 코드가 입력되어 변환된 이미지를 생성한다. mapping network는 MLP로 구성되며 랜덤 noise 값과 타겟 도메인을 샘플링하여 다양한 스타일 코드를 생성한다. style encoder는 reference 이미지에서 다양한 스타일 코드를 추출한다. 이러한 방식으로 생성된 스타일 코드가 generator에 반영된다. discriminator는 여러 output branch를 갖고 있으며 여러 도메인에 대한 진위 여부를 판별한다. 그림 2는 앞서 설명한 v1과 v2 모델 구조를 나타내며 이미지 생성 과정을 보여준다. 카라 도메인에 대해 각 모델이 지정된 조건에 따라 변환한 생

성 결과를 나타낸다.

III. 패션 스타일 변환 이미지 생성 방안

3.1 데이터셋 전처리

본 논문에서는 셔츠의 세부 아이템인 카라와 패턴에 대한 스타일 변환 연구를 진행하였다. 이를 위해 여러 국내 대형 온라인 쇼핑몰에서 셔츠 데이터를 수집했다. 우선 이미지 속 셔츠를 제외한 다른 영역은 최대한 배제하기 위해 상의를 인식할 수 있는 Mask R-CNN 모델을 생성하였다. 셔츠 이미지를 labalme 툴을 이용하여 레이블링한 annotation 파일을 만든 뒤에 coco format으로 변환하였고^[11] 이를 이용하여 모델 학습을 하였다.

학습된 Mask R-CNN 모델은 상의를 인식할 때 픽셀 단위로 객체 영역을 정확히 찾아낼 수 있으며 탐지된 객체를 포함하는 사각 영역을 표시할 수 있다. 본 연구에서는 이와 같은 방법으로 이미지 전처리 과정을 수행하였다. 그림 3은 앞서 설명한 이미지 전처리 과정이며 상의 객체 인식 Mask R-CNN 모델에 하나의 셔츠 이미지를 넣었을 때 결과 이미지 예시를 보여 준다.

이러한 방식으로 전처리된 셔츠 데이터셋을 이용하여 카라와 패턴에 대한 스타일 변환 이미지 생성 모델을 학습하기 위해 카라와 패턴의 세부 특징에 따라 지




그림 3. 셔츠를 인식하고 이미지를 자르는 전처리 과정
Fig. 3. Process of shirt recognition and cutting the image.

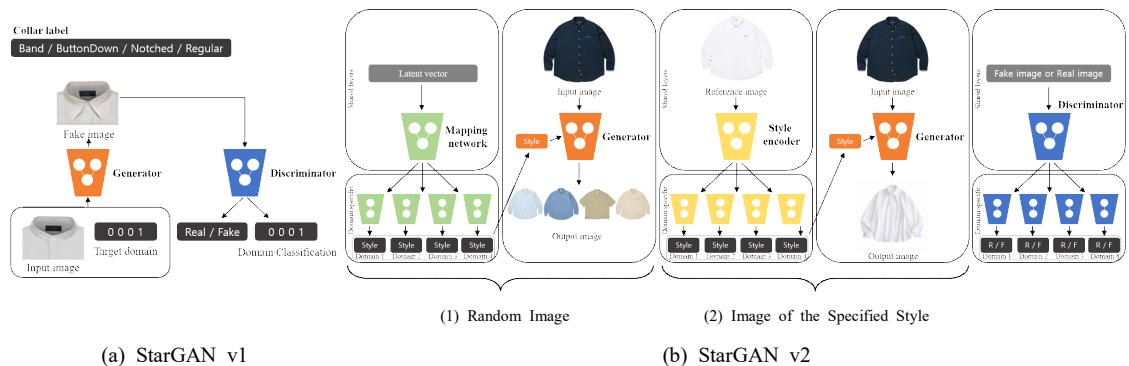


그림 2. StarGAN v1, v2 모델의 구조
Fig. 2. The structure of StarGAN v1, v2 model.




그림 4. 카라, 패턴 도메인을 시각화한 이미지
Fig. 4. Visualize image by collar, pattern domain.

정한 도메인대로 데이터셋을 분류했다. 그림 4에서 확인할 수 있듯이 카라는 Band, ButtonDown, Notched, Regular 4가지 클래스로 분류하였고, 패턴은 Check, Dot, Floral, Solid, Stripe 5가지 클래스로 분류하였다.

3.2 다중 도메인 변환 모델 생성

본 연구는 변환할 도메인을 지정할 수 있을 뿐만 아니라 다양한 스타일을 생성할 수 있는 StarGAN v2를 채택하여 이미지 생성 모델로 학습하였다. 카라와 패턴 도메인을 변환할 수 있는 하나의 모델을 생성하고자 한다면 각각의 클래스 개수를 곱한 값만큼 셔츠 데이터를 분류해야 한다. 반면 카라와 패턴 도메인에 대한 이미지 변환 모델을 따로 생성하게 된다면 두 클래스를 합한 값만큼만 분류된 데이터가 필요하므로 상대적으로 작은 크기의 데이터만으로 다중 도메인에 대한 이미지 변환 시스템을 구축할 수 있게 된다. 따라서 본 연구에서는 분류 클래스 축소와 이를 통한 클

래스별 요구 학습 데이터의 규모를 줄이기 위해 2-Step 학습 방안을 제시한다.

StarGAN v2 모델이 요구하는 input size에 알맞게 이미지 데이터를 모두 256 × 256 크기로 변환하고 각 GPU마다 batch size를 8로 지정하여 2대의 GPU로 학습을 진행하였다. 하나의 모델을 생성하는데 약 3일이 소요되었다.

카라 도메인 변환 모델 생성을 위해 셔츠 데이터를 지정한 클래스별로 1,500장씩 구분하여 총 6,000장의 학습 데이터셋을 구축하였다. 그림 5의 왼쪽 이미지는 학습된 모델에 입력한 이미지가 mapping network를 통해 다양한 스타일로 변환된 결과이고, 오른쪽 이미지는 학습된 모델에 다양한 source 이미지와 각 도메인별 reference 이미지를 입력하여 도출한 결과이다. source 이미지의 카라를 제외한 포켓, 단추 등 세부 아이템을 포함하여 전체적인 셔츠 형태가 유지된 채 reference 이미지의 카라 도메인 형태로 변환된 결과를 얻을 수 있다. 다만 색상은 reference 이미지의 대표 색상이 반영되고 패턴은 source 이미지가 갖는 패턴 형태가 반영되기 때문에 한가지 색상을 가진 reference 이미지와 민무늬의 source 이미지를 입력해야만 명확한 결과를 얻을 수가 있다.

패턴을 변환하기 위해서는 이미지의 색상이 중요하기 때문에 배경이 흰색이며 의류 착용자의 목 등 학습 장에요인이 배제된 셔츠 데이터를 선별하여 학습 데



그림 5. 카라 도메인 변환 모델이 생성한 결과 이미지 (왼쪽 : latent 코드 삽입, 오른쪽 : 참조 스타일 코드 삽입)
Fig. 5. Image generated as result of collar domain transformation model. (left : latent code injection, right : reference style code injection)

이더넷으로 구축하였다. 지정한 클래스별로 1,000장씩 총 5,000장으로 구성하였다. 또한, 학습된 패턴 도메인 변환 모델을 이용하여 source 이미지에 reference 이미지의 스타일을 반영하여 source 이미지의 카라를 포함한 전체적인 형태는 모두 유지된 채로 reference 이미지의 패턴이 합성된 결과를 도출하였다. 한편, solid를 제외한 패턴은 일정한 모양을 정의하기 어려울뿐더러 다양한 스타일을 갖기 때문에 형태를 정형

할 수 있는 카라 도메인 변환 모델보다 정확한 결과를 도출하기 어려웠다. 그림 6은 해당 모델로 생성한 결과 이미지이다. latent code를 이용하여 mapping network가 만든 다양한 생성 이미지와 입력한 reference의 style code가 반영된 결과를 나타낸다.

앞서 생성한 카라와 패턴 도메인 변환 모델을 이용하여 하나의 이미지를 입력하였을 때 원하는 카라와 패턴으로 변환되는 방안을 모색하였다. 카라 도메인



그림 6. 패턴 도메인 변환 모델이 생성한 결과 이미지 (왼쪽 : latent 코드 삽입, 오른쪽 : 참조 스타일 코드 삽입)
 Fig. 6. Image generated as result of pattern domain transformation model. (left : latent code injection, right : reference style code injection)

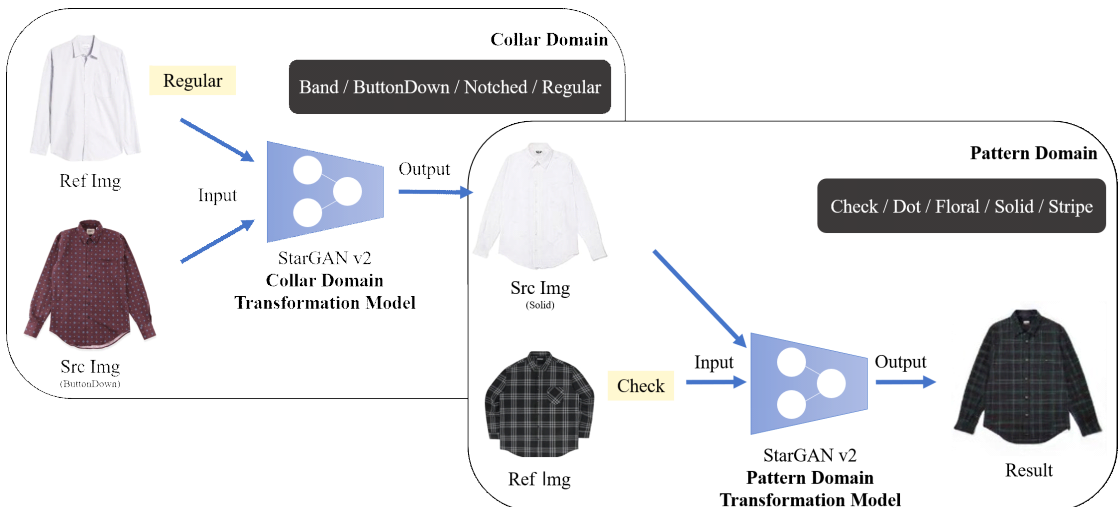


그림 7. 다중 도메인 스타일 변환 과정
 Fig. 7. Process of multi-domain style transformation.

변환 이미지 생성 모델을 이용하여 입력 이미지를 원하는 카라 형태로 변환한 후, 결과 이미지를 패턴 이미지 생성 모델의 source 이미지로 입력하여 reference 이미지의 패턴과 합성하면 카라와 패턴 모두 원하는 도메인으로 변환된 결과를 얻을 수 있다. 추가로 포켓과 같은 세부 아이템 형태를 source 이미지와 합성하면 더욱이 원하던 결과의 생성이 가능하다. 그림 7은 카라와 패턴 도메인 변환 모델을 이용하여 스타일을 변환한 결과를 생성하는 프로세스이다. 카라는 ButtonDown, 패턴은 Dot 특성을 지닌 하나의 셔츠 이미지에 대해 각각 Regular와 Check 스타일로 변환한 이미지를 생성하는 모습이다.

IV. 성능 평가

본 장에서는 StarGAN v2 이미지 생성 모델을 학습하는 동안 loss function을 측정한 후 그래프로 나타내어 알맞은 방향으로 학습되고 있는지 확인하고 학습된 여러 이미지 생성 모델의 FID^[12]를 측정하여 성능 평가 및 비교분석을 도출하고자 한다.

카라 도메인 변환 모델은 100,000, 패턴 도메인 변환 모델은 40,000으로 epoch를 설정하여 학습을 진행하였다. 또한, 설정된 epoch를 초과하여 학습을 진행할 경우, 불안정한 생성 이미지가 도출되었다. 그림 8은 모델을 학습시키는 동안에 측정한 generator와 discriminator의 loss function 결과를 나타내는 그래프이다. loss function은 실제 데이터와 학습된 모델의 예측값 사이의 차이를 나타내는 지표이다. 학습이 진행될수록 loss 값이 줄어들어 실제 데이터와 유사한 방향으로 학습이 진행된 것을 확인할 수 있다.

FID란 실제 이미지와 생성된 이미지 사이의 특정 거리를 측정하는 방식으로써, 실사 같은 이미지를 생성하고자 하는 GAN의 평가 지표 방식으로 활용되고 있다. 사전에 ImageNet으로 학습된 Inception v3 모

델을 이용하여 실제 이미지와 생성 이미지 사이의 Fréchet distance 거리를 측정한다. FID score가 작을수록 유사도가 높다고 판단할 수 있다.

FID는 식 (1)과 같이 연산된다. 실제 이미지와 가짜 이미지를 각각 Inception v3 모델을 이용하여 임베딩한 값이 r 과 f 이고, μ 는 평균, Σ 은 공분산, Tr 은 대각합을 의미한다.

$$FID(r, f) = \|\mu_r - \mu_f\|^2 + Tr(\Sigma_r + \Sigma_f - 2(\Sigma_r \Sigma_f)^{1/2}) \quad (1)$$

FID 측정을 위해 실제 이미지 데이터와 모델이 생성한 이미지 데이터를 각각 5,000장씩 구축하였다. 표 1은 StarGAN v1과 v2 각각의 카라 이미지 생성 모델과 패턴 이미지 생성 모델을 이용하여 생성한 이미지로 데이터셋을 구축하여 실제 이미지와 FID 측정을 진행한 결과이다. v2 모델은 reference 이미지를 다른 이미지에 입력 생성한 이미지와 latent code를 이용하여 생성한 이미지로 나눠 측정하였다. 측정된 FID 결과를 통해 v2 모델이 v1 모델보다 더 실제와 유사한 이미지를 생성한다는 것을 확인할 수 있다.

식 (1)을 따라 StarGAN v2 카라 모델의 latent code를 이용하여 생성한 이미지와 실제 이미지 사이의 FID는 평균 간의 차이 제곱 합 0.092, 대각합 0.95를 더하여 1.04를 얻게 되었다.

StarGAN v2 원문에서 사람 얼굴 이미지 데이터 CelebA-HQ의 Female과 Male을 도메인으로 지정하여 생성한 모델과 동물 얼굴 이미지 데이터 AFHQ의 Cat, Dog, Wildlife로 도메인을 지정하여 학습시킨 모델을 이용하여, reference code 방식으로 측정한 FID 결과는 각각 23.8, 19.8이다. 원문과 달리 본 연구에서는 배경이 깔끔하고 비교적 규모가 작은 셔츠 이미지 데이터를 이용하였다. 이러한 점을 고려해도 아주 작은 FID score 값을 얻었기 때문에 생성한 모델의 성능은 우수하다고 판단된다.




그림 8. 모델 학습에 따른 손실함수 그래프 (왼쪽 : 카라 도메인 모델 학습, 오른쪽 : 패턴 도메인 변환 모델 학습)
 Fig. 8. Loss function graph during learning the model. (left: learn collar domain model, right : learn pattern domain transformation model)

표 1. StarGAN v1, v2 모델의 FID 측정 결과
Table 1. Result of measuring FID by StarGAN v1 and v2.

Method	Collar	Pattern
	FID	
StarGAN v1	3.62	5.17
StarGAN v2 (latent code injection)	1.04	1.35
StarGAN v2 (reference style code injection)	2.07	1.84

그림 5와 그림 6의 이미지를 토대로 FID의 결과를 분석한 결과, 패턴의 Dot와 Floral 스타일 생성이 쉽지 않기 때문에 latent code를 이용하여 패턴 도메인 변환 모델의 mapping network에서 생성한 스타일을 합성한 결과와 비교할 때, 비교적 도메인에 대한 스타일이 정형된 카라 도메인 변환 모델이 생성한 이미지가 실제 이미지와 유사하다는 결과가 도출되었다. 반면, reference 이미지의 스타일을 추출하는 과정에서, 카라 도메인 변환 모델은 단일 색상만을 추출하기 때문에, 다양한 색상을 반영할 수 있는 패턴 도메인 변환 모델이 생성한 이미지와 실제 이미지 사이의 유사도 결과가 더 높다고 보여진다.

V. 결 론

본 논문에서는 패션 이미지의 세부적인 아이템의 스타일을 변환할 수 있는 방안을 모색하고자 하였다. 이를 위해 조건을 지정하여 원하는 스타일대로 변환된 이미지 생성이 가능한 StarGAN v2를 채택하여 다중 도메인 변환 모델을 생성하기 위한 연구를 진행하였다.

패션 아이템 중 셔츠 데이터를 수집하여 셔츠의 세부 아이템 카라와 패턴을 각각 대표적인 몇가지 특성별로 분류하여 데이터셋을 구축하였고, 상의를 인식할 수 있도록 학습한 Mask R-CNN 모델을 이용한 전처리를 진행하였다. 이를 이용하여 카라와 패턴 스타일 변환 모델을 각각 생성하였고 두 모델은 각각의 도메인에 대해 latent code를 이용하여 다양한 스타일의 결과를 낼 수도 있고, 지정한 도메인에 따른 reference 이미지의 스타일을 추출하여 이를 반영하는 것이 가능하다. 본 연구에서는 후자의 기능을 이용하여 두 모델을 모두 활용한 다중 도메인 변환 시스템을 구축하였다.

이러한 연구는 패션 분야 이미지 생성 및 이미지 기반 검색에 도움이 될 것이라 기대된다. 추후 다양한

패션 아이템의 세부 스타일 변환에 대한 연구를 지속할 예정이다.

References

- [1] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, et al., "Generative adversarial Nets," *Advances in NIPS* 27, 2014. (<https://doi.org/10.1145/3422622>)
- [2] H. Jang, et al., "Implementation of User-defined Style Transformation Scheme for Fashion Item based on GAN," in *Proc. KICS ICC 2022*, pp. 1750-1751, Jeju Island, Korea, Jun. 2022.
- [3] T. Karras, S. Laine, and T. Aila, "A style-based generator architecture for generative adversarial networks," in *Proc. IEEE/CVF Conf. CVPR*, 2019. (<https://doi.org/10.1109/cvpr.2019.00453>)
- [4] Mfrashad, *ClothingGAN: AI Powered Clothing Design Generator*(2020), Retrieved May, 23, 2022, from <https://github.com/mfrashad/ClothingGAN>.
- [5] Y. Choi, et al., "Stargan: Unified generative adversarial networks for multi-domain image-to-image translation," in *Proc. IEEE Conf. CVPR*, 2018. (<https://doi.org/10.48550/arXiv.1711.09020>)
- [6] Y. Choi, et al., "Stargan v2: Diverse image synthesis for multiple domains," in *Proc. IEEE/CVF Conf. CVPR*, 2020. (<https://doi.org/10.48550/arXiv.1912.01865>)
- [7] K. He, et al., "Mask r-cnn," in *Proc. IEEE Int. Conf. Computer Vision*, 2017. (<https://doi.org/10.48550/arXiv.1703.06870>)
- [8] R. Girshick, et al., "Rich feature hierarchies for accurate object detection and semantic segmentation," in *Proc. IEEE Conf. CVPR*, 2014. (<https://doi.org/10.1109/cvpr.2014.81>)
- [9] R. Girshick, "Fast r-cnn," in *Proc. IEEE Int. Conf. Computer Vision*, 2015. (<https://doi.org/10.1109/iccv.2015.169>)
- [10] S. Ren, et al., "Faster r-cnn: Towards real-time object detection with region proposal networks," *Advances in NIPS*, vol. 28, 2015.

(<https://doi.org/10.1109/tpami.2016.2577031>)

- [11] K. Wada, *Labelme: Image Polygonal Annotation with Python*(2016), Retrieved Mar., 22, 2021, from <https://github.com/wkentaro/labelme>. (<https://doi.org/10.5281/zenodo.5711226>)
- [12] M. Heusel, et al., “Gans trained by a two time-scale update rule converge to a local nash equilibrium,” *Advances in NIPS*, vol. 30, 2017. (<https://doi.org/10.48550/arXiv.1706.08500>)

이 재 호 (Jaeho Lee)



2005년 : 고려대학교 전자컴퓨터 공학과 석사
2008년~2013년 : 고려대학교 전기전자전파공학과 박사
2013년~2015년 : LG전자 차세대표준연구소 선임연구원
2015년~2019년 : 서원대학교 정보통신공학과 조교수

2020년~현재 : 덕성여자대학교 소프트웨어전공 조교수
<관심분야> WPAN, MAC, Bluetooth, Wi-Fi, Localization, NLP, Machine Learning
[ORCID:0000-0003-0455-9939]

장 혜 립 (Hyelim Jang)



2019년 3월~현재 : 덕성여자대학교 IT미디어공학과 학사과정
<관심분야> Machine Learning, GAN, Neural Network
[ORCID:0000-0003-2204-8286]

손 봉 기 (Bong-Ki Son)



2000년 : 충북대학교 전자계산학과 석사
2000년~2004년 : 충북대학교 전자계산학과 박사
2005년~2007년 : 서원대학교 컴퓨터정보통신공학부 교수
2009년~현재 : 서원대학교 소프트웨어학부 컴퓨터공학전공 교수

<관심분야> Deep Learning, Image Processing, Big Data
[ORCID:0000-0003-1425-5197]