

# Generative Adversarial Network을 이용한 한복 디자인

DiscoGAN, CycleGAN, Munit을 중심으로

A Hanbok Design using Generative Adversarial Network  
Focusing on DiscoGAN, CycleGAN and Munit

주 저 자 : 정유진 (Jeong, Yoojin)                      광운대학교 전자통신공학과

공 동 저 자 : 김경철 (Kim, Kyoung Chul)              광운대학교 전자통신공학과

교 신 저 자 : 손채봉 (Sohn, Chae-Bong)              광운대학교 전자통신공학과  
cbsohn@kw.ac.kr

## Abstract

Recently, there has been continuous research in fashion design using artificial intelligence. Among them, fashion designs using generation algorithms began to appear in the mid-2000s. Among generation algorithms, Generative Adversarial Network (GAN) is a method that produces plausible samples as generation models and discriminant models competitively trained. In this paper, style transfer methods were used to create Hanbok images based on contour images of Hanbok with GAN algorithm. Style transfer is a suitable way to create hanbok with a variety of designs but no large changes of shape. In this paper, we built our own color and contour images of hanbok dataset for applying style transfer. After that, we analyzed methods and results of design using DiscoGAN, CycleGAN, and Muint, which are representative style transfer methods. As a result, all three methods learned the transformation between the color domain and the contour domain to create a new hanbok image given the contour image. In addition to the basic hanbok design, it designed creative hanbok with new patterns and color changing tie. This paper demonstrates that it is possible to design hanbok using artificial intelligence and future development possibilities.

## Keyword

Traditional clothes, Generative Adversarial Network, Style transfer

## 요약

최근 패션 디자인 분야에서 인공지능을 사용하는 연구가 지속적으로 이루어지고 있다. 그 중 생성 알고리즘을 적용한 패션 디자인은 2000년대 중반부터 나타나기 시작했다. 생성 알고리즘 중 Generative adversarial network(GAN)은 생성 모델과 판별 모델이 경쟁적으로 학습하면서 실제와 유사한 결과를 만들어내는 방법이다. 본 논문은 GAN 알고리즘으로 윤곽 이미지로부터 한복 이미지를 생성하는 Style transfer 방법을 통해 한복을 디자인한다. Style transfer는 형태는 크게 변하지 않으며 스타일만 변화시키는 것으로 형태 변화는 크지 않지만 다양한 디자인이 존재하는 한복에 적합하다. 본 논문에서는 Style transfer를 적용하기 위한 한복 이미지와 윤곽 이미지 데이터 셋을 구현하였다. 그 후 대표적인 Style transfer 방법인 DiscoGAN, CycleGAN, 그리고 Muint을 활용해 윤곽 이미지에서 한복이미지를 생성하는 방법과 그 결과를 분석했다. 결과적으로 세 방법 모두 색상 영역과 윤곽 영역 사이의 변환을 학습함으로써 윤곽 이미지가 주어졌을 때 새로운 한복 이미지를 생성해냈다. 또한 기본적인 한복 디자인뿐만 아니라 새로운 한복 무늬나 색의 변화가 있는 옷고름과 같은 창의적인 한복 디자인을 얻을 수 있었다. 이를 통해 인공지능을 사용한 한복 디자인이 가능함과 앞으로의 개발 가능성을 보여준다.

## 목차

### 1. 서론

- 1-1. 연구 배경 및 목적
- 1-2. 연구 방법

### 2. 이론적 배경

- 2-1. Generative Adversarial Network 개념
- 2-2. Style transfer의 개념과 방법

### 3. GAN을 활용한 한복 디자인

- 3-1. DiscoGAN을 활용한 디자인
- 3-2. CycleGAN을 활용한 디자인
- 3-3. Munit을 활용한 디자인

## 4. 결론

### 참고문헌

## 1. 서론

### 1-1. 연구의 배경 및 목적

새로운 알고리즘이나 하드웨어 등이 개발됨에 따라 머신러닝 기술이 빠르게 발전하고 있다. 이에 따라 다양한 분야에서 딥러닝 기술과의 접목을 시도하고 있다. 인간의 영역이라 생각했던 음악과 미술과 같은 예술 창작 영역에서 딥러닝을 적용한 사례가 증가하고 있다.<sup>1)</sup> 아마존은 GAN으로 인간 디자이너 없이 옷을 디자인 하는 방법을 개발하고 있다. 아마존의 ai 디자이너는 인스타그램과 페이스북과 같은 소셜 미디어를 통해 패션 데이터를 확보하고 분석한 후 트렌디한 옷 디자인을 목표로 한다. Ivyrevel의 Coded Couture은 구글과 함께 사용자의 생활 패턴에 따라 옷을 디자인할 수 있는 기술을 발표했다. 이처럼 딥러닝 기술이 현대 패션 디자인에 응용되고 있지만 전통 의상 디자인에 대해서는 아직 연구가 필요하다. 우리나라의 전통 의상인 한복에는 저고리와 긴치마, 바지, 조끼, 두루마리 등이 있으며 계절과 상황에 따라 종류가 다양하다. 또한 한복은 고유의 재질과 색깔, 무늬 등을 가지고 있다. 따라서 이런 특징을 잘 학습하는 네트워크가 필요하다.

또한 최근 한국에 대한 관심이 증가함에 따라 우리나라의 문화와 전통에 대한 관심 역시 증가하고 있다. 이런 시대에 흐름과 대중의 요구에 따라 여러 한복 디자이너들은 색과 소재, 새로운 특징 등을 새롭게 접목하는 시도를 하고 있다. 본 논문은 딥러닝을 접목해 한복을 디자인한다. 이를 통해 딥러닝을 사용해 본격적인 한복 디자인에 앞서 보조적인 디자인 개발이 가능함을 보여준다.

본 연구에서는 한복을 디자인하는 방법으로 입력 이미지를 원하는 스타일의 이미지로 변환시키는 style transfer를 사용한다. 대표적인 style transfer GAN을 통해 한복의 윤곽 이미지가 주어졌을 때 한복을 디자인 할 수 있음을 보여준다.

### 1-2. 연구 방법

머신러닝은 크게 지도 학습, 비지도 학습, 강화학습으로 나뉜다. 지도학습은 정답이 존재하여 모델이 출력한 결과와 정답과의 오차를 줄여가며 학습하는 방법이다. 지도 학습의 예에는 분류, 회귀, 그리고 물체 인식 등이 있다. 반면 비지도 학습은 정답이 존재하지 않으며 데이터가 주어졌을 때 데이터의 패턴을 찾는다. 따라서 데이터의 특성을 분석하고 관계를 추론하는데 사용된다. Generative adversarial network(GAN)<sup>2)</sup>은 대표적인 비지도 학습에 속한다. 디자인은 정답이 정해져 있지 않으며 창의적인 결과를 기대한다. 따라서 새로운 결과를 얻기 위해서는 기존의 지도학습이 아닌 비지도 학습 방법이 필요하다.

윤곽 이미지를 한복으로 style transfer를 위해서 색상 이미지와 윤곽 이미지로 네트워크를 학습시켜야 한다. 따라서 색상 이미지와 윤곽 이미지가 필요하며 색상 이미지를 수집한 후 Holistically nested edge detection(HED)<sup>3)</sup>를 사용해 윤곽을 추출함으로써 데이터 셋을 구성했다. HED는 end-to-end 신경망을 사용해 학습된 윤곽 검출 방법으로 일정한 윤곽을 추출할 수 있다. 이미지에 따라 적절한 임계 값을 설정해야 하는 Canny edge의 단점을 보완한 방법이다. [그림 1]을 보면 HED의 장점을 볼 수 있다. HED를 통해 얻은 이미지가 옷의 경계를 더 정확히 알 수 있으며 노이즈가 적다. 또한 옷의 명암을 통해 전체적인 틀을 보다 쉽게 얻은 것을 볼 수 있다.

1) <http://areben.com>

2) I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. Generative adversarial nets. In NIPS, 2014, pp. 2672-2680

3) S. Xie and Z. Tu. Holistically-nested edge detection. In ICCV, 2015, pp. 1395-1403



[그림 1] HED와 Canny edge detection 비교. (a) 한복 이미지 원본. (b) HED 로 추출한 윤곽 이미지. (c) Canny Edge detection으로 추출한 윤곽 이미지.

트레이닝에 사용된 한복 이미지와 윤곽 이미지는 각각 4272장으로, 학습 이미지 3412장, 테스트 이미지 861장으로 구성되어있다. 이 데이터 셋을 사용해 한복 이미지와 윤곽 이미지 영역 사이의 변환을 학습한다. Style transfers는 색상 영역과 윤곽 영역 사이의 변환을 통해 Edge 이미지만으로 새로운 디자인을 만들어 내는데 적절하다. 그 중 GAN을 사용한 대표적인 DiscoGAN, CycleGAN, Muint을 사용해 한복 이미지 생성 방법과 결과를 분석해본다.

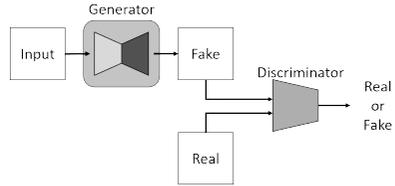
## 2. 이론적 배경

### 2-1. Generative Adversarial Network

Generative Adversarial Network은 생성 모델(Generator)과 판별 모델(discriminator)이 적대적인 학습(Adversarial learning)을 하는 네트워크이다. 생성 모델은 실제 데이터를 학습해 판별 모델이 진짜라 생각하는 거짓 데이터를 만드는 것을 목표로 한다. 판별 모델은 생성 모델이 만들어낸 데이터가 실제인지 거짓인지 정확히 판별하는 것을 목표로 학습한다. 두 개의 모델이 경쟁적으로 학습하면서 결과적으로 실제와 구분할 수 없는 거짓 데이터를 만들어낸다. 이를 수식으로 나타내면 다음과 같다.

$$\min_G \max_D V(D, G) = E_{x \sim p_{data(x)}} [\log D(x)] + E_{z \sim p_z(z)} [\log (1 - D(G(z)))]$$

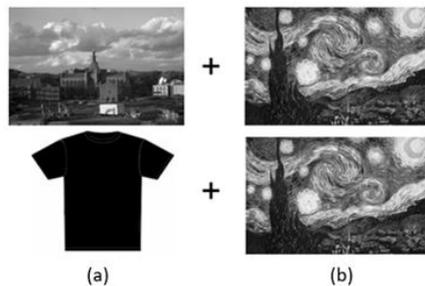
판별모델 D는  $V(D, G)$ 를 최대로 해야 한다. 따라서 실제 데이터에 대한 확률분포에서 샘플링 한 데이터(x)는 1, 생성 모델이 임의의 노이즈에서 샘플링 한 데이터(loss  $G(z)$ )는 0이 되도록 한다. 생성모델 G는  $V(D, G)$ 를 최소가 되도록 한다. 따라서 임의의 노이즈에서 샘플링 한 데이터( $D(G(z))$ )가 1이 되도록 한다.



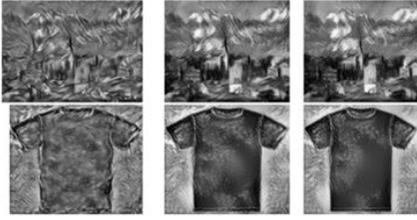
[그림 2] Generative Adversarial Network의 학습 과정.

### 2-2. Style transfer의 개념과 방법

Style transfer는 기존 이미지(content image)의 형태는 유지하면서 이미지의 스타일(style image)을 변화시키는 것이다. Style transfer에는 여러 방법이 존재하며 개발되어 왔다. 기본적으로 미리 학습된 네트워크를 사용하는 방법이 있다.<sup>4)</sup> 기존 이미지와 스타일 이미지를 각각 미리 학습된 모델에 통과시킨 후 얻은 특징 맵들이 비슷해지도록 최적화하면 [그림 3]과 같은 결과를 얻을 수 있다. 이러한 Style Transfer를 의상에 적용한다면 의상의 형태는 변하지 않은 채 원하는 무늬나 느낌을 가진 의상을 얻을 수 있다(그림 4). 한복의 경우 주로 형태는 일정하면서 색이나 무늬와 같은 디자인의 차이만 존재하기 때문에 Style Transfer의 적용이 용이하다.



4) L. A. Gatys, A. S. Ecker, and M. Bethge. Image style transfer using convolutional neural networks. CVPR, 2016, pp. 2414–2423



[그림 3] (a) Content Image, (b) Style Image, (c) Style Transfer된 이미지.



[그림 4] Style Transfer를 적용한 의상.

본 논문에서는 GAN을 이용해 style transfer 네트워크를 학습하는 방법을 사용한다. Pix2pix은 조건 GAN(conditional adversarial networks)을 사용하여 이미지에서 이미지로의 변환(image to image translation)을 구현하는 방법이다.<sup>5)</sup> GAN의 생성 모델과 판별 모델에 어떤 이미지를 생성할지 조건을 설정하는 cGAN 손실 함수를 사용한다. 그리고 생성된 이미지와 실제 이미지의 픽셀 차(L1 loss)를 추가하여 좀 더 뚜렷한 결과를 얻는다. 이를 다음과 같은 수식으로 나타낸다.

$$L_{cGAN}(G, D) = E_{x,y}[\log D(x,y)] + E_{x,z}[\log(1 - D(x, G(x,z)))]$$

$$L_{L1}(G) = E_{x,y,z}[\|y - G(x,z)\|_1]$$

$$G^* = \arg \min_G \max_D L_{cGAN}(G, D) + \lambda L_{L1}(G)$$

예를 들어 흑백 이미지(x)를 컬러 이미지(y)로 변환하고 싶다면 흑백이미지와 그에 대응하는 컬러 이미지를 input으로 설정한다. 판별모델 D는 컬러 이미지(y)가 1이 되고 임의의 노이즈에서 샘플링 한 데이터(G(z))는 0이 되도록 한다. 생성모델 G는 G(z)가 1이 되도록 한다. 하지만 기본 GAN과 차이점은 판별 모델과 생성 모델에 조건 x를 추가했다는 점이다. 마지막으로

5) P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros. Image-to-image translation with conditional adversarial networks. CVPR, 2017, pp. 1125-1134

로 컬러이미지(y)와 x로부터 만들어진 이미지(G(x,z))의 차를 합한다.

하지만 Pix2pix의 경우 원래 이미지와 변환하고자 하는 이미지의 정답 결과(ground truth)가 쌍으로 존재해야 한다. 그러나 변환하고자 하는 이미지를 가지고 있는 경우는 드물다. DiscoGAN과 CycleGAN은 생성된 이미지가 다시 자기 자신으로 돌아오게 하는 방법을 사용해 데이터가 쌍으로 존재하지 않아도 다른 이미지 스타일로 변환이 가능하다. 두 네트워크의 아이디어는 동일하다. 서로 다른 이미지 도메인 A, B가 존재할 때 A 도메인에서 B 도메인으로 변환한 후 다시 A 도메인으로 돌아오도록 학습한다. B의 경우도 A 도메인으로 변환 후 B 도메인으로 변환되도록 두 개의 GAN을 사용한다. 하지만 손실 함수에 차이가 있다. DiscoGAN의 손실 함수는 다음과 같다. A 도메인을 B로 매핑( $x_{AB} = G_{AB}(x_A)$ )한 후 B를 A로 매핑( $x_{BA} = G_{BA} \circ G_{AB}(x_A)$ )한다.  $L_{GAN_B}$ 는 판별 모델이 A 도메인에서 B 도메인으로 변환된 데이터를 진짜라 판단하도록 생성 모델을 학습시킨다.  $x_A$ 와  $x_{ABA}$ 의 차를 복원 손실(Reconstruction loss)로 정의한다. 판별 모델의 손실  $L_{D_B}$ 와  $L_{D_A}$ 는 기본 GAN과 같다. 따라서 DiscoGAN의 생성 모델의 손실은 두 개의 GAN 손실과 두 개의 복원 손실의 합이고 판별 모델 손실은 두 판별 모델의 손실의 합이다.

$$L_{G_{AB}} = L_{GAN_B} + L_{const_A}, L_{G_{BA}} = L_{GAN_A} + L_{const_B}$$

$$L_G = L_{G_{AB}} + L_{G_{BA}}$$

$$L_D = L_{D_A} + L_{D_B}$$

CycleGAN의 손실 함수는 다음과 같이 구성되어 있다. G는 X에서 Y로 매핑하는 함수이며  $D_Y$ 는 이를 판별한다.

$$L_{GAN}(G, D_Y, X, Y) = E_{y \sim P_{data(y)}}[\log D_Y(y)] + E_{x \sim P_{data(x)}}[\log(1 - D_Y(G(x)))]$$

F는 Y에서 X로 매핑하는 함수이며  $D_X$ 로 판별한다. 목적 함수는 위의 식과 유사하다. 이미지 변환 사이클은 x가 매핑을 두 번 거쳐 자기 자신으로 돌아오도록( $x \rightarrow G(x) \rightarrow F(G(x)) \approx x$ )한다. 이를 위해 원래 자기 자신과 매핑 결과의 차이를 손실(cycle consistency loss)로 정의한다.

$$L_{cyc}(G, F) = E_{x \sim P_{data(x)}}[\|F(G(x)) - x\|_1] + E_{y \sim P_{data(y)}}[\|G(F(y)) - y\|_1]$$

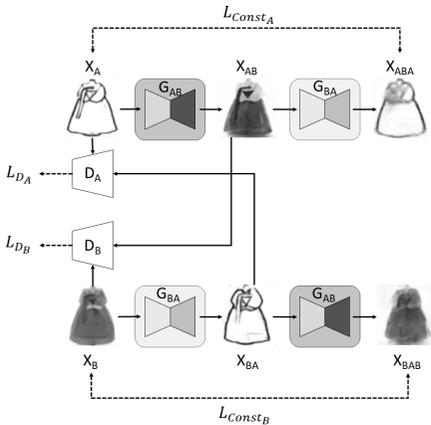
따라서 결과적으로 CycleGAN의 목적함수는 다음과 같다.

$$L(G, F, D_X, D_Y) = L_{GAN}(G, D_Y, X, Y) + L_{GAN}(F, D_X, Y, X) + \lambda L_{cyc}(G, F)$$

### 3. GAN을 활용한 한복 디자인

#### 3-1. DiscoGAN<sup>6)</sup>을 활용한 디자인

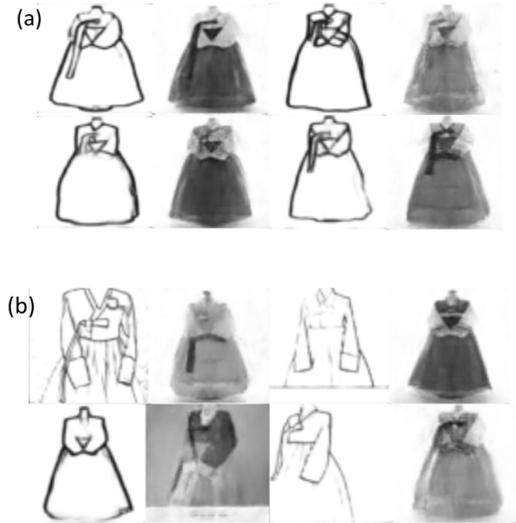
DiscoGAN은 논문 제목에서 알 수 있듯이 GAN을 사용해 서로 다른 도메인 사이의 관계를 발견한다. [그림 5]에서 A는 한복, B는 윤곽을 의미한다.  $G_{AB}$ 는 한복 이미지에서 윤곽 이미지를 생성하는 생성 모델,  $G_{BA}$ 는 윤곽 이미지로부터 한복 이미지를 생성하는 생성 모델이다.  $D_A, D_B$ 는 각각 한복 이미지와 윤곽 이미지를 판별하는 판별 모델이다. DiscoGAN에서 A는 A 도메인의 이미지( $G_A$ )를 생성 모델에 통과시켜 이미지를 생성한다( $G_{AB}$ ). 판별 모델로 생성된 이미지( $G_{AB}$ )가 해당 도메인( $G_B$ )인가를 판단한다. 그리고 생성 모델을 추가해 반대로 가는 매핑을 학습시켜 원본 도메인에서 벗어나지 않도록 한다. B도 같은 방법으로 학습된다.



[그림 5] DiscoGAN을 사용한 한복 이미지 생성 방법.

DiscoGAN의 생성 모델이 단순한 인코더-디코더 구조를 가지기 때문에 학습 시간이 비교적 짧다. 하지만 해상도가 낮아 전체적인 형태와 색 이외에는 흐릿해

학습 결과가 좋지 않다. [그림 6]를 보면 전체적인 한복의 형상만 나타나며 치마, 저고리, 옷고름 사이의 구분이 뚜렷하지 않음을 볼 수 있다. 또한 [그림 6]의 (b)를 보면 윤곽 이미지와 전혀 다른 형태의 한복을 그려내는 것을 볼 수 있다. 이는 입력( $G_A, G_B$ )과 출력( $G_{ABA}, G_{BAB}$ ) 사이의 차를 줄이는 복원 손실이 학습된 이미지가 해당 도메인의 이미지처럼 보이게 하는 위한 의미 없는 매핑임을 알 수 있다.



[그림 6] 윤곽 이미지와 DiscoGAN을 이용해 디자인된 한복 이미지. (a) 결과의 해상도가 낮음. (b) 결과가 해당 도메인의 이미지일 뿐 입력과 관련 없음.

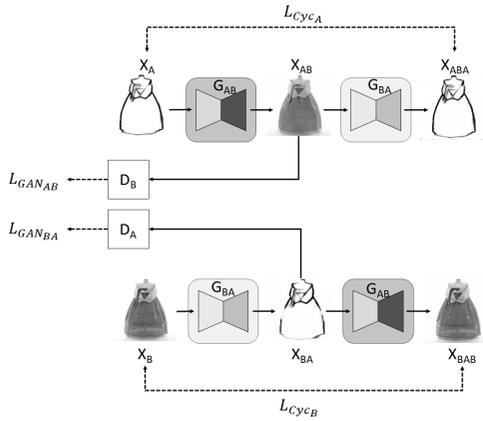
#### 3-3. CycleGAN<sup>7)</sup>을 활용한 디자인

DiscoGAN의 경우 한 방향으로 매핑 되기 때문에 무의미한 매핑 결과를 얻는다. 따라서 의미 있는 매핑이 되기 위해서는 위해서 양방향으로의 매핑이 되어야 한다. CycleGAN은 매핑과 그 결과가 다시 반대로 매핑을 시키는 순환 구조이다. 즉, 원 상태로 돌아오는 양방향 매핑을 학습한다. 또한 DiscoGAN과 달리 순환 일치 손실(cycle-consistency loss)을 통해 형태는 크게 변하지 않으면서 스타일만 변환시킨다. 마지막으로 Resnet구조의 생성 모델을 사용함으로써 기술기 소실 문제를 해결한다. 결과적으로 DiscoGAN보다 학습이

6) T. Kim, M. Cha, H. Kim, J. K. Lee, and J. Kim. Learning to discover cross-domain relations with generative adversarial networks. ICML, 2017, pp. 1857–1865

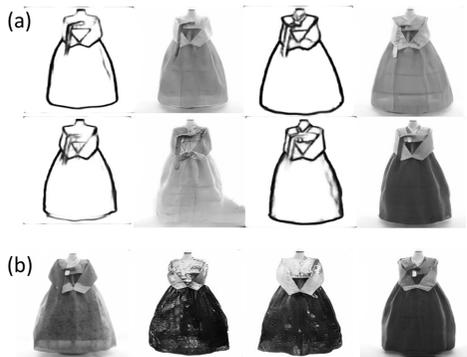
7) S. J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros. Unpaired imager-to-image translation using cycle-consistent adversarial networks. ICCV, 2017, pp. 2223–2232

잘 되었으며 이미지의 해상도가 좋다.



[그림 7] CycleGAN을 사용한 한복 이미지 생성 방법.

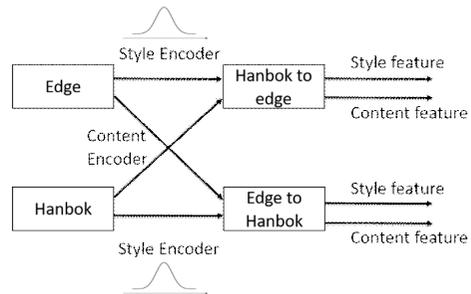
학습 결과 형태는 거의 변하지 않고 다채로운 색, 한복의 무늬, 주름 등 한복의 특징을 잘 생성한다. [그림 8]을 보면 비교적 해상도가 높으며 한복의 형태나 질감이 실제 한복과 매우 유사하다. 다른 한편으로는 기존 한복과 다른 새로운 형태의 한복을 생성하는 것을 볼 수 있다. [그림 8]의 (a)에서 데이터 셋에는 존재하지 않았던 옷고름의 색상 변화나 무늬를 생성했다. (b)를 보면 치마의 질감과 무늬를 새롭게 만들어낸 것을 볼 수 있다. 즉, 본 논문의 목표인 윤곽 이미지로 생성 이미지를 변환하고자 하면서 새로운 한복을 디자인하는 작업에 적합하다.



[그림 8] (a) 윤곽 이미지와 CycleGAN을 이용해 디자인된 한복 이미지. (b) 새로운 한복 무늬 생성.

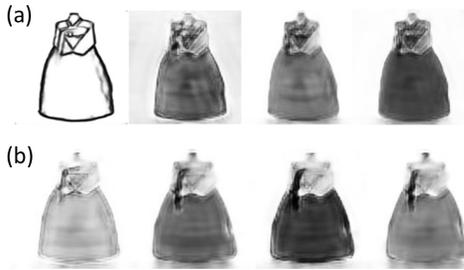
### 3-2. Munit을 활용한 디자인

DiscoGAN과 CycleGAN은 하나의 도메인에서 다른 도메인으로 매핑(one-to-one mapping)이다. 하지만 Munit은 여러 도메인 사이의 매핑(many-to-many cross-domain mapping) 방법으로 한 장의 사진을 다양한 이미지로 변환 가능하다. 한복은 대부분 비슷한 형태를 가지고 있으므로 한 장의 윤곽 이미지로 다양한 색의 디자인을 만들 수 있다면 더 효율적이다. 모델은 두 개의 오토인코더로 구성된다. 각각은 여러 도메인에서 공통적으로 나타나는 추상적인 특징을 의미하는 내용 코드(content code)와 특정 도메인만의 특징 스타일 코드(style code)로 구성된다. 즉 서로 다른 도메인과 공유하는 공통 내용 영역과 자기만의 스타일 영역을 가진다. [그림 9]에서 Munit를 사용해 한복 이미지를 생성하는 과정을 볼 수 있다. 우선 윤곽 이미지와 한복 이미지에서 각각 스타일 특징과 내용 특징을 추출한다. 그 후, 윤곽의 내용과 한복의 스타일을 사용해 윤곽에서 한복 이미지로 변환한다. 윤곽에서 한복으로 변환할 때는 GAN 손실을 사용한다. 그리고 변환된 이미지에서 스타일과 특징과 내용 특징을 추출해 변환 전의 특징들과의 차를 손실로 사용한다. 즉 GAN 손실과 L1 손실의 합인 손실 함수를 사용해 학습한다.



[그림 9] Munit을 사용한 한복 이미지 생성 방법

학습 결과 한 장의 윤곽 이미지로 여러 색조합의 한복 이미지를 생성해낸다. 하지만 이미지의 해상도와 완성도가 좋지 않은 것을 볼 수 있다. 이는 학습 시 에폭을 늘려도 손실이 줄어들지 않았기 때문이다. 따라서 하이퍼 파라미터들을 적절히 수정한다면 더 나은 결과를 얻을 수 있을 것이다. 또한 데이터 셋의 이미지에서 한복 형태가 대부분 비슷했기 때문에 한정적인 특징을 뽑았을 가능성이 있다.



**[그림 10] (a) 윤곽 이미지와 Munit을 이용해 디자인된 한복 이미지. (b) 결과의 해상도가 낮음.**

## 5. 결론

본 연구는 생성모델을 이용해 우리나라 전통 의상인 한복을 디자인 할 수 있음을 보여준다. 그 중 Style transfer 방법을 사용하는 대표적인 GAN 세 가지를 사용해 실험했다. DiscoGAN은 비교적 간단하고 짧은 시간이 소요되었으나 해상도가 좋지 않았으며 주어진 윤곽 이미지와 상관없는 한복 이미지를 추출하기도 했다. Munit은 주어진 한복 데이터 셋을 이용해 내용 특징과 스타일의 특징을 추출하는데 부족했으며 결과적으로 해상도가 낮았다. 하지만 하나의 윤곽 이미지로 여러 디자인이 가능하다는 장점이 있었다. CycleGAN은 해상도가 높았으며 윤곽 이미지가 주어졌을 때 그에 맞는 디자인을 얻을 수 있었다. 특히 CycleGAN의 경우 데이터 셋에 없는 새로운 한복 무늬나 색의 변화가 있는 옷고름을 만들어냈다. 이를 통해 GAN을 통해 만들어진 한복 디자인이 한국적 정서, 문화와 미를 온전히 담기에는 아직 어려움이 있지만, 한복 디자이너들의 디자인 개발에 도움이 될 것임을 확신한다. 더 나아가 Style transfer를 사용한다면 여자 한복으로부터 남자 한복으로 변환, 한복 스타일의 현대 의상 디자인, 한복 스타일의 제품을 디자인 등 다양한 방면으로 응용이 가능할 것이다. 이후에는 전통 문양이나 질감을 더 잘 살리며 다양한 디자인을 위해 TextureGAN과 같은 GAN 알고리즘을 적용 할 예정이며 더 나아가다면 한복 디자인에 특화된 네트워크를 구현할 수 있을 것이다.

## 참고문헌

1. Shuhui Jiang, d Yun Fu, Fashion Style Generator. In IJCAI, 2017.
2. I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. Generative adversarial nets. In NIPS, 2014.
3. S. Xie and Z. Tu. Holistically-nested edge detection. In ICCV, 2015.
4. L. A. Gatys, A. S. Ecker, and M. Bethge. Image style transfer using convolutional neural networks. CVPR, 2016.
5. P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros. Image-to-image translation with conditional adversarial networks. In CVPR, 2017.
6. T. Kim, M. Cha, H. Kim, J. K. Lee, and J. Kim. Learning to discover cross-domain relations with generative adversarial networks. In ICML, 2017.
7. Xun Huang, Ming-Yu Liu, Serge Belongie, Jan Kautz, Multimodal Unsupervised Image-to-Image Translation, In ECCV, 2018.
8. J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros. Unpaired imageto-image translation using cycle-consistent adversarial networks. In ICCV, 2017.
9. <http://areben.com>