

특집논문 (Special Paper)

방송공학회논문지 제26권 제1호, 2021년 1월 (JBE Vol. 26, No. 1, January 2021)

<https://doi.org/10.5909/JBE.2021.26.1.61>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

## 딥러닝 기반 이미지 아웃페인팅 기술의 현황 및 최신 동향

김 경 훈<sup>a)</sup>, 공 경 보<sup>b)</sup>, 강 석 주<sup>a)†</sup>

### A Review on Deep Learning-based Image Outpainting

Kyunghun Kim<sup>a)</sup>, Kyeongbo Kong<sup>b)</sup>, and Suk-ju Kang<sup>a)†</sup>

#### 요 약

이미지 아웃페인팅은 이미지의 맥락을 고려하여 주어진 이미지의 외부를 지속적으로 채울 수 있다는 점에서 매우 흥미로운 문제이다. 이 작업에는 두 가지 주요 과제가 있다. 첫 번째는 생성된 영역의 내용과 원래 입력의 공간적 일관성을 유지하는 것이다. 두 번째는 적은 양의 인접 정보로 고품질의 큰 이미지를 생성하는 것이다. 기존의 이미지 아웃페인팅 방법은 일관되지 않고 흐릿하며 반복되는 픽셀을 생성하는 등 어려움을 겪고 있다. 하지만 최근 딥러닝 기술의 발달에 힘입어 기존의 전통적인 기법들에 비해 높은 성능을 보여주고 있는 알고리즘들이 소개되었다. 딥러닝 기반 아웃 페인팅은 현재까지도 다양한 네트워크가 제안되며 활발히 연구되고 있다. 본 논문에서는 아웃 페인팅 분야의 최신 기술 현황 및 동향을 소개하고자 한다. 딥러닝 기반의 아웃페인팅 알고리즘 중 대표적인 네트워크들을 분석하고 다양한 데이터 셋과 비교 방법을 통한 실험 결과를 보여줌으로써 최근 기법들을 비교하고자 한다.

#### Abstract

Image outpainting is a very interesting problem in that it can continuously fill the outside of a given image by considering the context of the image. There are two main challenges in this work. The first is to maintain the spatial consistency of the content of the generated area and the original input. The second is to generate high quality large image with a small amount of adjacent information. Existing image outpainting methods have difficulties such as generating inconsistent, blurry, and repetitive pixels. However, thanks to the recent development of deep learning technology, deep learning-based algorithms that show high performance compared to existing traditional techniques have been introduced. Deep learning-based image outpainting has been actively researched with various networks proposed until now. In this paper, we would like to introduce the latest technology and trends in the field of outpainting. This study compared recent techniques by analyzing representative networks among deep learning-based outpainting algorithms and showed experimental results through various data sets and comparison methods.

Keyword : image completion, image restoration, image outpainting, extrapolation

## 1. 서론

최근 딥러닝의 발전과 함께 영상 완성(image completion)에 대한 연구가 활발히 진행되고 있으며 다양한 응용분야에서 뛰어난 성능을 보이고 있다. 영상 완성 분야의 대표적인 예로는 저해상도에서 고해상도 영상으로 복원하는 슈퍼레졸루션, 영상 내부의 훼손된 영역을 의미적, 인지적으로 자연스럽게 생성하는 이미지 인페인팅과 영상 외부의 영역을 자연스럽게 생성하는 이미지 아웃페인팅이 있다. 위와 같은 영상 복원 기법들은 Generative Adversarial Networks(GANs) 기법이 제안된 이래로 많은 성능 향상을 이끌어냈다. GANs는 적대적 생성 신경망으로써, generator를 통하여 생성된 이미지를 discriminator가 진위여부를 판별하는 형태로 구성되어 있다. Generator는 discriminator가 판별할 수 없는 수준의 영상을 생성해내고, discriminator는 생성 영상의 진위여부를 판별하는 능력을 강화하는 형태로 적대적인 학습방법을 사용하는 방법이다. GANs는 영상 생성에 효과적인 특징을 가지는 방법으로, 영상 복원 방법에서 많이 사용되고 있다.

이미지 아웃페인팅은 그림 1. (c)와 같이 입력 영상의 바깥 영역을 생성해내는 방법이다. 생성된 출력 영상은 공간

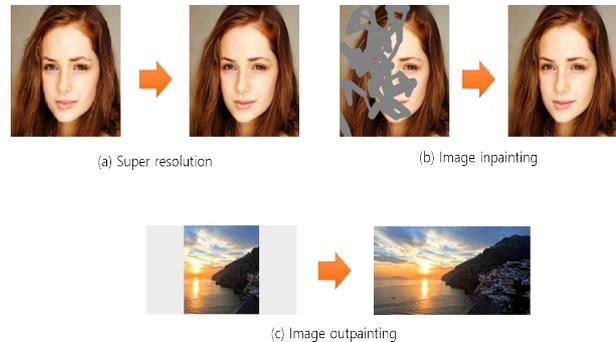


그림 1. 이미지 완성 분야의 예  
Fig. 1. image completion field example

적, 인지적으로 자연스러운 영상을 생성하는 것을 목표로 한다. 생성하고자 하는 영역의 인접정보가 전방향으로 존재하는 인페인팅 분야와는 달리, 아웃페인팅은 입력영상으로부터의 인접정보가 한 방향으로만 존재한다. 인접정보가 한 방향인 경우, convolution 연산 시 입력영상과의 거리가 멀어질수록 입력 영상에 대한 정보가 희미해지면서 공간적인 해석이 어렵고 반복적인 픽셀 값을 출력하게 된다. 따라서, 인접정보가 여러 방향에 존재할수록 더 자연스럽게 질 좋은 영상을 생성해내기에 적합하다. 이러한 문제로 인해 이미지 아웃페인팅은 성능 개선에 큰 어려움을 겪고 있으며, 인페인팅에 비해 연구가 부족한 편이다.

아웃페인팅의 응용분야 중에 하나는 이미지 리타겟팅 분야에서의 활용이 있다. 이미지 리타겟팅이란 각기 다른 디스플레이의 종횡비에 맞춰 이미지를 리사이징하는 기술을 말한다. 세부 기술로는 내용 기반 리타겟팅이 있는데, 이는 원 영상 내에서 상대적으로 중요한 물체가 존재하는 영역의 원형은 유지시키고, 상대적으로 덜 중요한 영역의 왜곡은 허용함으로써, 리사이징으로 인한 영상의 시각적 품질 저하를 경감시키는 기술이다. 특히 디스플레이의 크기가 영상의 크기보다 클 경우, 즉 이미지를 디스플레이 크기에 맞게 크게 리사이징할 때 아웃페인팅을 활용하면 원본 영상 전체를 왜곡시키지 않고 부족한 영역만큼만 이미지를 새로 생성하여 채울 수 있으므로 이미지 리타겟팅 분야에서 높은 잠재력을 가지는 기술이다.

a) 서강대학교 전자공학과(Dept. of Electronic Engineering, Sogang Univ.)  
b) 포항공과대학교(Pohang University of Science and Technology)

‡ Corresponding Author : 강석주(Suk-Ju Kang)

E-mail: sjkang@sogang.ac.kr

Tel: +82-2-705-8466

ORCID: <https://orcid.org/0000-0002-4809-956X>

※ 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터지원사업의 연구결과로 수행되었으며 (IITP-2021-2018-0-01421), 2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단-나노미래소재원천기술개발사업의 지원을 받아 수행된 연구(No. 2020M3H4A1A02084899)이며, 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2018R1D1A1B07048421).

※ This research was supported by the MSIT(Ministry of Science and ICT), Korea, under the ITRC(Information Technology Research Center) support program(IITP-2021-2018-0-01421) supervised by the IITP(Institute of Information & communications Technology Planning & Evaluation) and supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. 2020M3H4A1A02084899) and supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. 2018R1D1A1B07048421).

· Manuscript received November 30, 2020; Revised January 7, 2021; Accepted January 7, 2021.

## II. 딥러닝 기반의 이미지 인페인팅 알고리즘 기술 현황 및 동향

이번 장에서는 이미지 아웃페인팅을 소개하기 앞서, 가장 관련 깊은 분야인 이미지 인페인팅을 먼저 설명하겠다. 이미지 인페인팅은 영상의 내부 영역이 훼손되었을 때, 훼손된 영역(unknown region)을 자연스럽게 채워 넣는 기법이다. 해당 기법은 영상의 훼손되지 않은 영역(known region)의 정보를 이용하여 영상의 특징을 추출하고 최대한 의미적으로 자연스러운 영상을 생성하는 것이 목적이다. 이미지 인페인팅의 고전적인 방법<sup>[1][2][3][4]</sup>은 patch의 similarity나 diffusion에 의존하여 훼손되지 않은 영역으로부터 훼손된 영역에 대한 정보를 가져와서 채워 넣는다. 이러한 방법은 훼손된 영역이 작은 경우에는 효과적이지만 훼손된 영역이 커지면 의미론적 분석이 되지 않아서 좋은 성능을 내지 못한다.

최근에는 Generative Adversarial Networks(GANs)<sup>[5]</sup> 이

라는 딥러닝 기반의 영상 생성 모델이 제안된 이래로 GANs을 사용한 이미지 인페인팅 방법<sup>[6][7][8]</sup>들이 등장하기 시작했으며 그 성능 또한 많은 성장을 이뤄내고 있다. Lizuza et al.<sup>[6]</sup>은 GANs 기반의 방법으로서, generator를 통하여 생성된 영상을 두 개의 discriminator를 사용하여 영상을 학습하는 방법을 사용하였다. 두 discriminator 중 하나는 Global discriminator로 출력된 전체 영상에 대하여 진위 여부를 판별하는 네트워크이며, 다른 하나는 Local discriminator로 unknown region에 대한 출력 영상에 대해서만 진위 여부를 판별하였다. 이를 통해, 전체적인 영상의 context와 복원된 영역에 해당하는 생성된 영상의 질을 높일 수 있었다.

Guilin et al.<sup>[7]</sup>은 일반적인 convolution 연산이 아닌 partial convolution을 제안하여 이미지 인페인팅을 수행하였다. 일반적인 convolution 연산을 수행할 때는 전체 영상에 동일하게 연산이 진행된다. 하지만 partial convolution을 사용

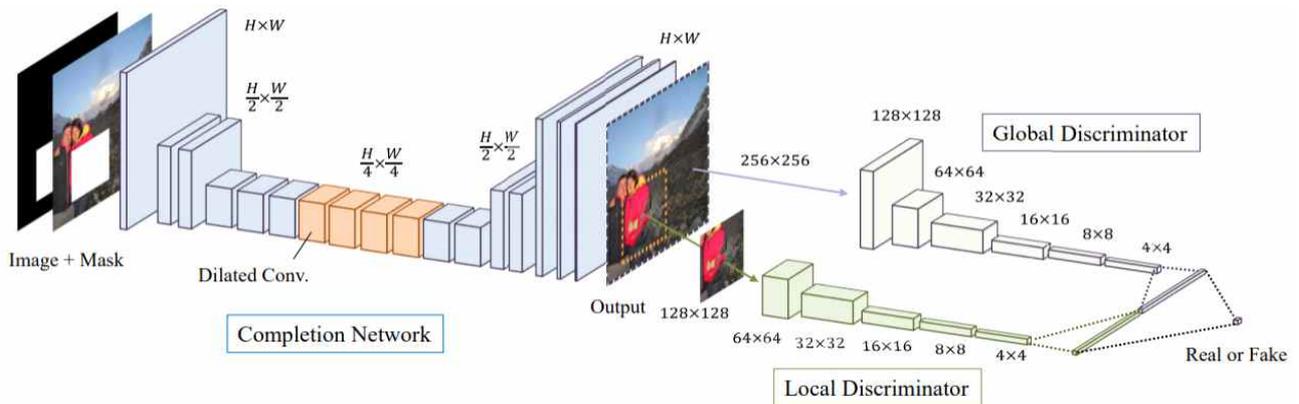


그림 2. Lizuza et al.<sup>[6]</sup>: 네트워크 구조  
Fig. 2. Lizuza et al.<sup>[6]</sup>: overall network

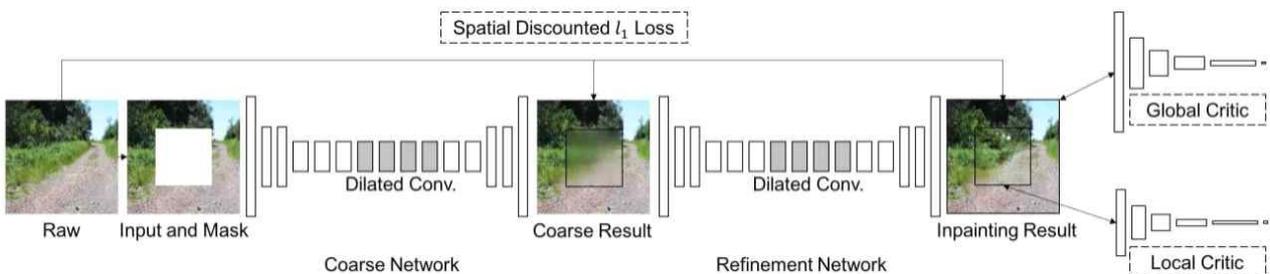


그림 3. Jiahui et al.<sup>[8]</sup>: 네트워크 구조  
Fig. 3. Jiahui et al.<sup>[8]</sup>: overall network

하면 유효 픽셀에만 적용되도록 제한하여 영상 생성에 불필요한 특징 값을 제거할 수 있다. Guilin et al.<sup>[7]</sup>은 정규화를 통하여 kernel에 적용되는 영역이 unknown region만 존재하는 경우에는 convolution 연산이 적용되지 않도록 하면서 점점 마스크의 영역을 좁혀가며 복원을 수행하는 방법을 제안했다.

Jiahui et al.<sup>[8]</sup>는 coarse network와 refinement network 두 단계의 generator를 통하여 coarse-to-fine 방법을 사용하였고 Contextual Attention (CA)을 통하여 known region의 정보로부터 훼손된 영역에 대하여 유의미한 feature를 복사하여 생성되는 영역에 대하여 디테일을 살릴 수 있도록 유도하였다. 하지만, 이는 인접정보가 풍부하고 입력영상과 훼손된 영역 간의 정보가 연관성이 높아야 하는 한계가 있다.

### III. 딥러닝 기반의 이미지 아웃페인팅 알고리즘 기술 현황 및 동향

이번 장에서는 대표적인 딥러닝 기반의 이미지 아웃페인팅 알고리즘 기술들에 대해 자세히 살펴보고자 한다. 먼저 가장 최초로 딥러닝 기반의 GANs 알고리즘을 적용한 사례인 Image-Outpainting<sup>[13]</sup>에 대해 알아보겠다. 이후 이미지 아웃페인팅에 적절한 네트워크를 설계한 Outpainting-srn<sup>[15]</sup> 알고리즘과 siamese 네트워크를 활용한 알고리즘<sup>[16]</sup>, 기존 인페인팅 네트워크를 활용하여 성능을 크게 높인 POAI<sup>[19]</sup> 알고리즘에 대해 소개하겠다.

고전적인 이미지 아웃페인팅 방법<sup>[9][10][11][12]</sup>은 딥러닝을 사용하지 않고 patch의 similarity를 보고 후보들을 고르고 가장 유사한 걸로 채워 넣는 방법이다. 이러한 방법은 앞서 인페인팅에서 소개한 고전 방법들과 마찬가지로 생성하고자 하는 영역이 커지면 좋은 성능을 내지 못하는 한계가 있다. 출력 화질을 향상시키기 위해 GAN을 사용하는 몇 가지 방법<sup>[13][14][15][16][19]</sup>이 이후 제안되었다. Sabini et al.<sup>[13]</sup> 처음으로 GAN 기반의 방법을 제안했다. 이 방법은 간단한 인코더-디코더 구조로 구성되며 평균 제곱 오차 (MSE)와 GAN 손실만 사용한다<sup>[5]</sup>. 후처리를 사용하여 출력 이미지를 부드럽게 하지만 생성된 이미지에서 반복되는 픽셀을 생성하는 한계가 있다.

Teterwak et al.<sup>[14]</sup>는 사전 훈련된 딥 네트워크의 의미 정

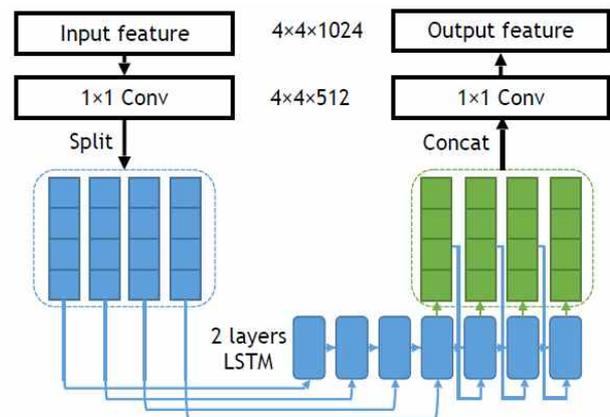


그림 4. Teterwak et al.<sup>[14]</sup> : RCT (Recurrent Content Transfer)  
Fig. 4. Teterwak et al.<sup>[14]</sup> : RCT (Recurrent Content Transfer)

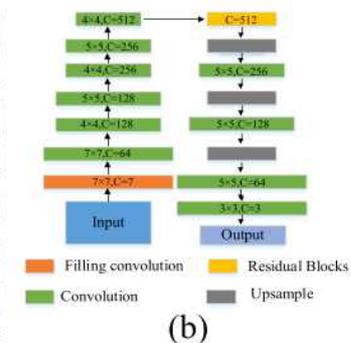
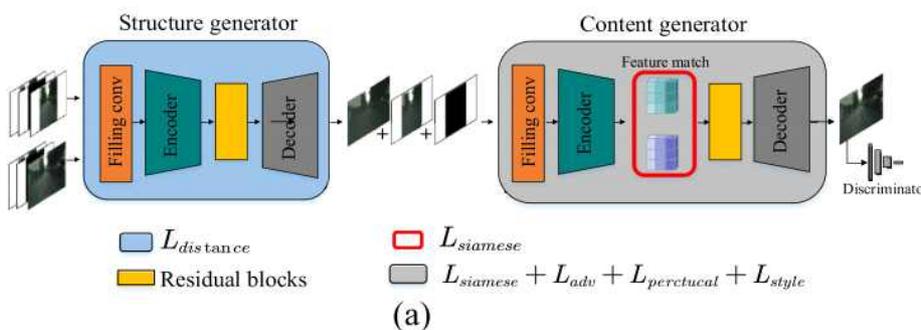


그림 5. Zhang et al.<sup>[16]</sup>. 네트워크 구조 설명. (a)는 네트워크 통합 학습. (b)는 구조 생성기의 자세한 구조  
Fig. 5. Zhang et al.<sup>[16]</sup>. Illustration of network architecture. (a) is the joint training pipeline of network. (b) is the detailed structure of structure generator

보를 기반으로 판별자의 동작을 조절하는 훈련을 위한 안정화 기법인 판별기에서 의미적 조건화를 사용했다. Yang et al.<sup>[13]</sup>은 장단기 기억 (LSTM)을 기반으로 한 RCT (Recurrent Content Transfer) 모듈을 제안했다. RCT는 입력 영역 특징을 예측 영역으로 전송하여 입력 영역과 예측 영역 간의 자연스러운 연결을 개선한다. 그러나 생성된 영역은 인접한 입력 영역의 특징을 비교적 크게 반영한다. 따라서 생성된 전체 영역이 입력 이미지의 중요한 특징인 색조와 일치하지 않는 경향이 있었다. 이 문제를 해결하기 위해 스타일 손실<sup>[17]</sup>과 지각 손실<sup>[18]</sup>을 적용한다. 이러한 손실을 사용하여 시맨틱 콘텐츠는 입력 이미지의 색조와 같은 스타일 측면의 일관성이 유지되며 품질을 향상시킬 수 있었다.

Zhang et al.<sup>[16]</sup>은 아웃페인팅 작업에 특화된 Siamese adversarial two-stage network와 adaptive filling convolution 이라고 부르는 경계에 민감한 convolution을 제안한다. 이는 부드러움과 특징의 균형을 유지하면서 알려진 콘텐츠 외부의 주변 픽셀의 특징을 자동으로 추론한다. 이 adaptive filling convolution은 2단계 네트워크의 인코더에 삽입되어 경계 기능에 대한 인코더의 감도를 활성화한다. 따라서 인코더는 알려지지 않은 콘텐츠를 추론할 수 있고 디코더의 추론 부담을 완화하는 효과를 가져온다. 또한, 인코더의 추

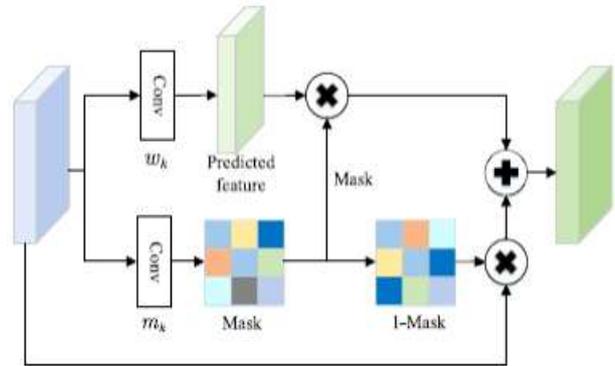


그림 6. Zhang et al.<sup>[16]</sup>: 적응형 컨볼루션 구조  
 Fig. 6. Zhang et al.<sup>[16]</sup>: Scheme of adaptive filling convolution

론 능력을 강화하기 위해 Siamese adversarial mechanism을 설계하여 먼 거리의 특징 분포를 알려지지 않은 이미지 특징 분포에 모델링할 수 있도록 한다.

최근 Kim et al.<sup>[19]</sup>은 양방향 경계 영역 재배열을 사용한 새로운 이미지 아웃페인팅 방법을 제안했다. 이는 자연영상에 대한 아웃페인팅 작업 시 이미지의 양끝이 유사하다는 사실을 이용하여 아웃페인팅보다 처리가 쉬운 이미지 인페인팅으로 문제를 변형하여 문제 해결을 시도했다. 양방향 경계 영역 재배열은 이미지 인페인팅 작업과 유사한 양방향 정보를 이용하여 누락된 영역을 생성할 수 있도록

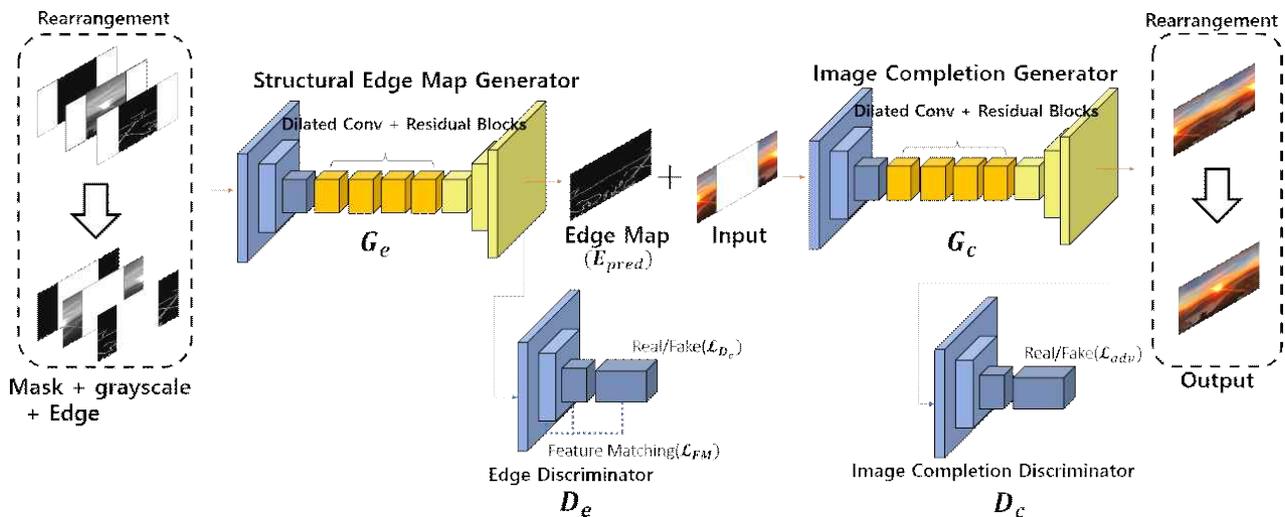


그림 7. Kim et al.<sup>[19]</sup>: 네트워크의 전체 아키텍처. 모델은 에지 맵 생성 네트워크와 이미지 완성 네트워크의 두 부분으로 구성  
 Fig. 7. Kim et al.<sup>[19]</sup>: Overall architecture of network. model comprises two parts: an edge map generation network and an image completion network

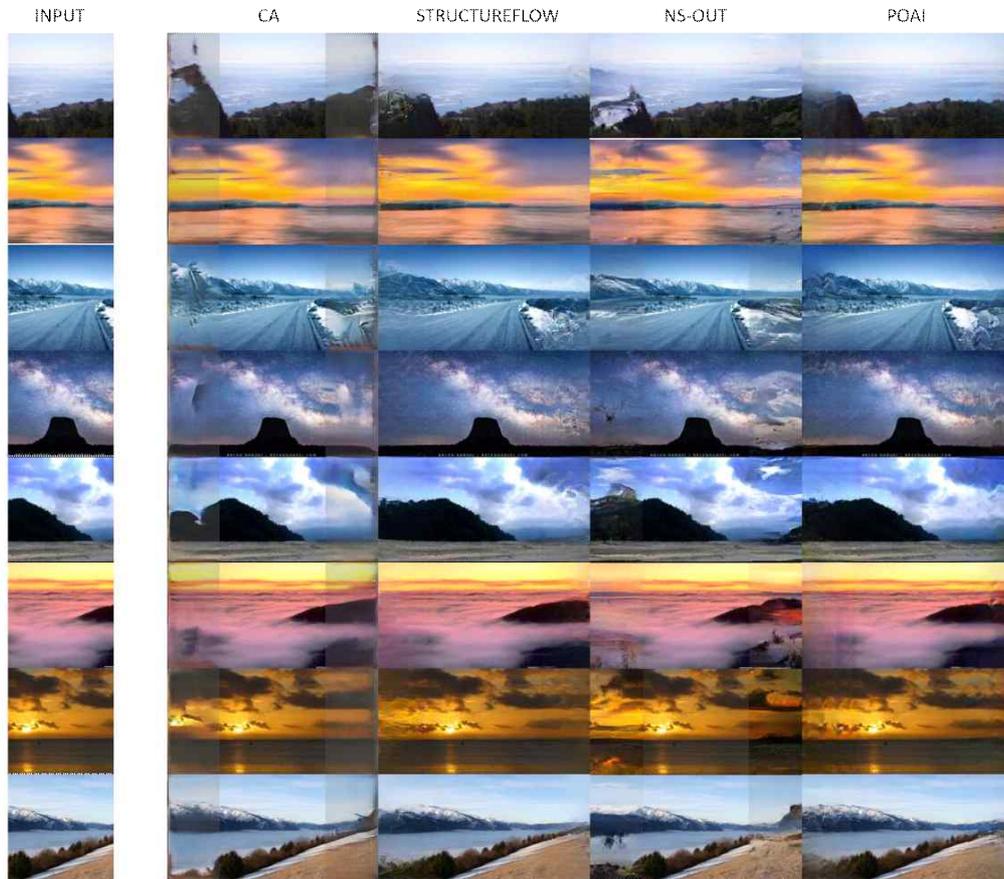


그림 8. 정성적 결과 비교표  
Fig. 8. qualitative result

하여, 단방향 정보를 사용하는 기존 방식보다 높은 품질의 이미지를 생성할 수 있다. 또한, 이미지를 구조 정보가 포함된 원본 입력으로 간주하고 미지 영역의 가장자리를 복원하여 이미지를 생성하는 Edge Map 생성기를 사용하였다.

#### IV. 알고리즘 결과 성능 비교

이번 장에서는 딥러닝 기반 이미지 아웃페인팅 알고리즘을 평가할 때 널리 쓰이는 데이터셋인 SUN<sup>[20]</sup>, Beach<sup>[24]</sup>에 대한 출력 영상의 결과를 살펴보고자 한다. 정량적 평가 방법으로는 영상의 화질을 평가하는 대표적인 평가 매트릭

인 PSNR(Peak Signal-to-Noise Ratio)과 SSIM(Structural SIMilarity)과 GAN을 평가하는 대표적인 평가 매트릭인 IS(Inception Score)<sup>[22]</sup>와 FID(Frénchet Inception Distance)<sup>[23]</sup>, 그리고 No-reference image quality assessment(IQA) 매트릭 중 하나인 BRISQUE<sup>[21]</sup>를 사용하여 출력 영상의 자연스러움을 평가하였다.

Table 1은 기존 인페인팅 알고리즘과 아웃페인팅 알고리즘을 아웃페인팅 작업에서의 성능 결과를 비교한 표이다. 인페인팅 알고리즘을 아웃페인팅 작업에 아무런 조작없이 수행할 경우 결과 성능이 좋지 못함을 알 수 있다. 가장 최근 나온 PAOI<sup>[19]</sup> 알고리즘은 모든 평가 지표에서 우수한 성능을 보여주고 있다. Table 2는 Beach dataset에서 아웃페인팅 알고리즘들의 성능 결과를 비교한 표이다.

표 1. SUN dataset<sup>[20]</sup>에서의 정량적 결과 비교. Inception Score (IS)<sup>[22]</sup>, PSNR과 SSIM은 높을수록 좋으며, Frénchet Inception Distance FID<sup>[23]</sup>과 BRISQUE<sup>[21]</sup>은 낮을수록 좋음. 평가 데이터셋의 IS 는 3.479.

Table 1. Quantitative results for models on SUN dataset<sup>[20]</sup>. Evaluation of Inception Score (IS)<sup>[22]</sup>, PSNR and SSIM(the higher, the better), Frénchet Inception Distance FID<sup>[23]</sup> and BRISQUE<sup>[21]</sup> (the lower, the better). Images from the validation set had an IS of 3.479.

Method	IS	FID	PSNR	SSIM	BRISQUE
CA [8]	2.93	19.04	20.42	0.84	24.46
NS-OUT [13]	2.85	13.71	19.53	0.72	23.59
POAI [19]	3.20	15.72	22.45	0.86	21.61

그림 8은 인페인팅 방법 CA<sup>[8]</sup> 과 NS-OUT<sup>[13]</sup>, POAI<sup>[19]</sup>의 정성적 결과 비교 이미지이다. CA<sup>[8]</sup>는 일관성이 없는 물체를 생성하며 원본 이미지와 큰 색상 차이를 보이는 이미지를 생성했다. POAI<sup>[19]</sup>는 원본 이미지와 명확하게 연결되고 NS-OUT<sup>[13]</sup>보다 더 부드럽고 일관된 이미지를 생성하는 것을 볼 수 있다.

표 2. beach 데이터셋에 대한 성능 비교  
Table 2. Performance on beach dataset

Method	SSIM	PSNR
Image-Outpainting <sup>[13]</sup>	0.338	14.625
Outpainting-sm <sup>[15]</sup>	0.513	18.221
SieNet <sup>[16]</sup>	0.646	20.796
POAI <sup>[19]</sup>	0.810	18.957

## V. 결론

본 논문에서는 인공지능 기술, 특히 심층학습을 이용한 이미지 아웃페인팅 알고리즘 기술 현황 및 동향에 대해 살펴보았다. 다양한 크기의 디스플레이 시장이 커지고 그에 따라 기존의 영상 콘텐츠를 다양한 디스플레이 크기에 맞추려는 리타겟팅 기술의 필요성이 꾸준히 제기되고 있으나 아직 기존의 리타겟팅 기술로는 영상 크기를 더 넓은 디스플레이 크기에 맞추는 부분에서 여전히 어려움을 겪고 있다. 이를 해결하기 위해 딥러닝 기반의 네트워크를 이용하여 이미지 아웃페인팅 기술을 통해 문제 해결하려는 연구가 진행되고 있다. 딥러닝 기반 아웃페인팅 알고리즘은 원본 영상을 훼손하지 않은 채, 새롭게 이미지를 생성하여 불

여 효과적으로 영상 크기를 늘릴 수 있다. 하지만 여전히 이미지 아웃페인팅 기술은 자연 영상과 같은 단순한 영상에서만 효과를 보이며 높은 연산량을 가지고 있는 딥러닝 네트워크를 이용해야 하는 단점이 있다. 앞으로 실제 디스플레이에 해당 알고리즘을 구현하기 위해서는 모델 압축 및 최적화 연구와 다양하고 복잡한 영상에서도 동작할 수 있는 추가적인 연구가 필요하다.

## 참고 문헌 (References)

- [1] Ballester, C., Bertalmio, M., Caselles, V., Sapiro, G., & Verdera, J. (2001). Filling-in by joint interpolation of vector fields and gray levels. *IEEE transactions on image processing*, 10(8), 1200-1211.
- [2] Marcelo Bertalmio, Guillermo Sapiro, Vincent Caselles, and Coloma Ballester. Image inpainting. In *Proceedings of the 27th annual conference on Computer graphics and interactive techniques*, pages 417 - 424. ACM Press/AddisonWesley Publishing Co., 2000.
- [3] Alexei A Efros and William T Freeman. Image quilting for texture synthesis and transfer. In *Proceedings of the 28th annual conference on Computer graphics and interactive techniques*, pages 341 - 346. ACM, 2001
- [4] Alexei A Efros and Thomas K Leung. Texture synthesis by non-parametric sampling. In *Proceedings of the seventh IEEE international conference on computer vision*, volume 2, pages 1033 - 1038. IEEE, 1999
- [5] Goodfellow, Ian and Pouget-Abadie, Jean and Mirza, Mehdi and Xu, Bing and Warde-Farley, David and Ozair, Sherjil and Courville, Aaron and Bengio, Yoshua. Generative adversarial nets. In *Advances in neural information processing systems*, pages 2672 - 2680, 2014.
- [6] Iizuka, Satoshi, Edgar Simo-Serra, and Hiroshi Ishikawa. "Globally and locally consistent image completion." *ACM Transactions on Graphics (ToG)* 36.4 (2017): 1-14.
- [7] Liu, Guilin, et al. "Image inpainting for irregular holes using partial convolutions." *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018.
- [8] Yu, Jiahui, et al. "Generative image inpainting with contextual

- attention." Proceedings of the IEEE conference on computer vision and pattern recognition. 2018.
- [9] Johannes Kopf, Wolf Kienzle, Steven Drucker, and Sing Bing Kang. Quality prediction for image completion. *ACM Transactions on Graphics (TOG)*, 31(6):131, 2012.
- [10] Josef Sivic, Biliانا Kaneva, Antonio Torralba, Shai Avidan, and William T Freeman. Creating and exploring a large photorealistic virtual space. 2008.
- [11] Miao Wang, Yu-Kun Lai, Yuan Liang, Ralph R. Martin, and Shi-Min Hu. Biggerpicture: Data-driven image extrapolation using graph matching. *ACM Trans. Graph.*, 33(6):173:1 - 173:13, Nov. 2014.
- [12] Yinda Zhang, Jianxiong Xiao, James Hays, and Ping Tan. Framebreak: Dramatic image extrapolation by guided shiftmaps. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1171 - 1178, 2013.
- [13] Yang, Zongxin, et al. "Very Long Natural Scenery Image Prediction by Outpainting." *Proceedings of the IEEE International Conference on Computer Vision*. 2019.
- [14] Teterwak, Piotr and Sarna, Aaron and Krishnan, Dilip and Maschinot, Aaron and Belanger, David and Liu, Ce and Freeman, William T. Boundless: Generative adversarial networks for image extension. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 10521 - 10530, 2019.
- [15] Yi Wang, Xin Tao, Xiaoyong Shen, and Jiaya Jia. Wide context semantic image extrapolation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 1399 - 1408, 2019.
- [16] Zhang, X., Chen, F., Wang, C., Tao, M., & Jiang, G. P. (2020). Sienet: Siamese expansion network for image extrapolation. *IEEE Signal Processing Letters*, 27, 1590-1594.
- [17] Gatys, Leon A and Ecker, Alexander S and Bethge, Matthias. Image style transfer using convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2414 - 2423, 2016.
- [18] Johnson, Justin and Alahi, Alexandre and Fei-Fei, Li. Perceptual losses for real-time style transfer and superresolution. In *European conference on computer vision*, pages 694 - 711. Springer, 2016.
- [19] Kim, K., Yun, Y., Kang, K. W., Kong, K., Lee, S., & Kang, S. J. (2021). Painting Outside As Inside: Edge Guided Image Outpainting via Bidirectional Rearrangement With Progressive Step Learning. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision* (pp. 2122-2130).
- [20] Xiao, Jianxiong and Hays, James and Ehinger, Krista A and Oliva, Aude and Torralba, Antonio. Sun database: Largescale scene recognition from abbey to zoo. In *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 3485 - 3492. IEEE, 2010.
- [21] Anish Mittal, Anush Krishna Moorthy, and Alan Conrad Bovik. No-reference image quality assessment in the spatial domain. *IEEE Transactions on image processing*, 21(12):4695 - 4708, 2012.
- [22] Salimans, Tim and Goodfellow, Ian and Zaremba, Wojciech and Cheung, Vicki and Radford, Alec and Chen, Xi. Improved techniques for training gans. In *Advances in neural information processing systems*, pages 2234 - 2242, 2016.
- [23] Heusel, Martin and Ramsauer, Hubert and Unterthiner, Thomas and Nessler, Bernhard and Hochreiter, Sepp. Gans trained by a two time-scale update rule converge to a local nash equilibrium. In *Advances in neural information processing systems*, pages 6626 - 6637, 2017.
- [24] Mark Sabini and Gili Rusak. Painting outside the box: Image outpainting with gans. *arXiv preprint arXiv:1808.08483*, 2018.

---

저 자 소 개

---



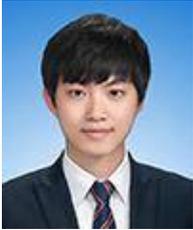
**김 경 훈**

- 2019년 : 연세대학교 컴퓨터공학과 학사
- 현재 : 서강대학교 전자공학과 석사과정
- ORCID : <https://orcid.org/0000-0002-3196-3470>
- 주관심분야 : 컴퓨터 비전, 딥러닝, 다중 객체 추적

---

저 자 소 개

---



**공 경 보**

- 2015년 : 서강대학교 전자공학과 학사
- 2017년 : 포항공과대학교 전자전기공학과 석사
- 2020년 : 포항공과대학교 전자전기공학과 공학박사
- 현재 : 포항공과대학교 전자전기공학과 박사후 연구원
- ORCID : <https://orcid.org/0000-0002-1135-7502>
- 주관심분야 : 노이즈 라벨 학습, 딥러닝, EEG 신호 분류



**강 석 주**

- 2006년 : 서강대학교 전자공학과 학사
- 2011년 : 포항공과대학교 전자전기공학과 공학박사
- 2011년 ~ 2012년 : LG Display 선임연구원
- 현재 : 서강대학교 전자공학과 부교수
- ORCID : <https://orcid.org/0000-0002-4809-956X>
- 주관심분야 : 멀티미디어 영상신호처리, 컴퓨터 비전, 딥러닝 시스템 설계