

논문 2022-17-39

# 잡음 제거 기술 기반의 비디오 인페인팅 성능 연구

## (A Study on the Video Inpainting Performance using Denoising Technique)

서 정 윤, 백 한 결, 박 상 효\*

(Jeong-yun Seo, Han-gyul Baek, Sang-hyo Park)

Abstract : In this paper, we study the effect of noise on video inpainting, a technique that fills missing regions of video. Since the video may contain noise, the quality of the video may be affected when applying the video inpainting technique. Therefore, in this paper, we compare the inpainting performance in video with and without denoising technique DAVIS dataset. For that, we conducted two experiments: 1) applying inpainting technique after denoising the noisy video and 2) applying the inpainting technique to the video and denoising the video. Through the experiment, we observe the effect of denoising technique on the quality of video inpainting and conclude that video inpainting after denoising would improve the quality of the video subjectively and objectively.

Keywords : Deep learning, Noise reduction, Video denoising, Video inpainting

### I. 서 론

현재 컴퓨터 비전 분야는 빠른 속도로 성장하고 있다. 컴퓨터 비전의 분야 중 인페인팅 (inpainting) 기술은 이미지의 누락되거나 손상된 영역을 주변 배경과 유사하게 채우는 기술로 이미지 또는 영상 편집과 객체 제거, 손상 복원, 워터마크 제거 등의 용도로 쓰일 수 있다. 인페인팅 기술은 크게 이미지 인페인팅 (image inpainting)과 비디오 인페인팅 (video inpainting) 두 개의 분야로 나누어진다. 지금까지 인페인팅에 관한 많은 연구가 이루어졌지만, 완벽한 인페인팅 알고리즘을 구현하는 데는 어려움을 겪고 있다. 이미지 인페인팅 기법은 고전적인 비학습 기반 (non-learning based) 인페인팅 기술 [1-4]과 학습 기반 (learning based) 기법으로 나눌 수 있다 [5-8]. 학습 기반의 이미지 인페인팅을 위해서는 생성적 적대 신경망 (Generative Adversarial Network, GAN) [9]이 주로 사용된다. 비디오 인페인팅은 영상의 누락된 영역을 채우거나 특정 물체를 제거하고 손상된 영역을 복원하는 데 사용된다는 점이 이미지 인페인팅과 유사하다. 하지만 인페인팅 기술을 영상의 영역으로 확장하기 때문에 영상의 연속된 프레임 간 시공간적인 일관성을 보존하는 기술이 요구된다. 비디오 인페인팅 기술을 위해 프레임 간 시공간적 일관성을 보존하려는 시도는 많았지만, 현실 세계의 노이즈가 포함된 영상에 인페인팅을 적용할 때

나타나는 문제점은 거의 다루어지지 않았다. 그러나 어두운 장소에서 촬영된 영상과 같이 현실 세계에서 촬영된 영상에는 불가피하게 노이즈가 포함되어 있고, 이것은 영상에 인페인팅 기술을 적용할 때 영상 품질에 영향을 줄 수 있다. 따라서 본 논문에서는 인페인팅 기술을 사용할 때 영상의 잡음 제거 여부가 인페인팅 결과에 미치는 영향에 대해 연구하여 비디오의 품질을 개선할 방법을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서 인페인팅과 관련된 기존 연구와 한계를 소개한다. 3장에서는 제안하는 인페인팅 기법과 실험 방법을 설명하고, 4장에서 그 결과를 분석했다. 마지막으로 5장에서는 결론으로 마무리한다.

### II. 관련 연구

#### 1. 이미지 인페인팅

##### 1.1 비학습 기반 이미지 인페인팅

고전적인 비학습 기반의 인페인팅 기술은 크게 패치 기반 방법과 확산 기반 방법으로 나눌 수 있다. 패치 기반의 인페인팅 모델 [1, 2]은 알려진 영역 (known region)의 픽셀 정보를 통해 이미지의 훼손된 영역을 채운다. 확산 기반의 인페인팅 모델 [3, 4]은 손상된 영역 주변의 정보를 손상된 영역 (missing region)으로 전파하여 이미지를 완성한다. 그러나 이러한 비학습기반의 인페인팅 기법들은 계산 복잡도가 높고, 손상된 영역이 클 때는 의미론적인 정보를 파악할 수 없다는 한계가 있다.

##### 1.2 학습 기반 이미지 인페인팅

딥러닝 기술이 비약적으로 발전함에 따라 컴퓨터 비전 분야에도 딥러닝을 도입하게 되었다. 최근 인페인팅 기술에도 딥러닝을 적용한 연구가 활발하게 이루어지고 있다. [5]는

\*Corresponding Author (s.park@knu.ac.kr)

Received: Oct. 19, 2022, Revised: Oct. 25, 2022, Accepted: Nov. 26, 2022.

J. Y. Seo: Kyungpook National University (B.S. Student)

H. K. Baek: Kyungpook National University (M.S. Student)

S. H. Park: Kyungpook National University (Asst. Prof.)

※ 이 논문은 2020년도 정부 (교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업인 (No. 2020R111A3072227).

※ 이 논문의 연구 결과 중 일부는 한국통신학회 “제3회 한국 인공지능 학술대회”에서 발표한 바 있음.

기존 이미지 인페인팅 기술을 개선하기 위해 부분 컨볼루션 층을 도입했다. 이전의 딥러닝 기반 인페인팅 기술은 이미지에 컨볼루션 필터를 사용해 이미지의 빈 영역을 고정 값으로 채웠다. 하지만 초기의 이미지 구멍 값에 의존하기 때문에 구멍의 질감이 부족하고, 복원 가능한 손상 영역이 직사각형 모양에 한정되며 색상의 대비와 부자연스러운 가장 자리를 가진다는 문제가 있었다. 따라서 부분 컨볼루션을 통해 손상된 부분에 대한 마스크 업데이트와 재정규화를 진행했다. 그 결과 커널을 통과하는 픽셀이 손상된 부분이면 계산을 수행하지 않고 통과하여 구멍이 아닌 영역에만 컨볼루션 연산을 수행하여 이미지를 완성하도록 했다.

먼저, [6]에서는 부분 컨볼루션 연산은 각 층을 지날 때마다 유효하지 않은 픽셀이 사라지면서 마스크의 모든 값이 1로 변하기 때문에 인페인팅을 위한 정보를 제공할 수 없으며 모든 채널이 같은 마스크를 공유하기 때문에 유연성이 제한된다는 문제를 제기했다. 따라서 게이트된 합성곱(gated convolution) 연산을 통해 최적의 마스크를 자동으로 학습하는 방법을 제안했다. 이미지의 공간 위치와 이미지 특성(feature)에 가중치를 곱한 값을 연산하여 마스크를 학습하고, Spectral-Normalized Markovian Discriminator (SN-PatchGAN)를 도입해 이진 마스크와 함께 사용자 주도의 인페인팅(user-guided inpainting)을 가능하게 했다. 또한, [7]의 인페인팅 모델은 크게 완성 네트워크(completion network), 전역 판별 네트워크(global discriminator network), 지역 판별 네트워크(local discriminator network) 세 개의 네트워크로 이루어진다. 먼저 이미지와 마스크를 완성 네트워크에 입력해 손상 이미지를 복구하고 두 개의 판별 네트워크를 통해 복구된 이미지의 진위 여부를 판별하여 인페인팅 결과가 손상된 영역 주변뿐만 아니라 이미지 전체적으로 일관성을 가지도록 한다. 완성 네트워크는 일반적인 컨볼루션 연산이 아닌 확장된 컨볼루션 연산을 통해 더 넓은 부분을 파악하여 연산하고 계산량을 줄이도록 개선했다. 생성적 적대 모델을 사용하는 또 다른 기법인 [8]의 이미지 인페인팅 모델은 거친 네트워크(coarse network)와 개선 네트워크(refinement network)로 이루어져 있어 손상된 이미지를 coarse-to-fine 기법으로 인페인팅 했다. 기존의 합성곱 신경망을 사용하는 기법들은 빈 영역과 떨어져 있는 픽셀 정보를 참고할 수 없었기 때문에 문맥 주의(contextual attention)를 사용해 알려진 영역의 유의미한 특성을 손상된 영역에 반영하여 생성 이미지의 품질을 개선했다.

## 2. 비디오 인페인팅

비디오 인페인팅 기술은 이미지 인페인팅 기술과 달리 프레임 간의 시공간적인 일관성을 유지해야 한다는 문제가 있다. Deep Flow-Guided Video Inpainting [10] 모델은 영상 흐름 기반의 픽셀 전파를 통해 영상의 시공간적인 일관성을 보존하고자 했다. Deep Flow Completion Network (DFC-Net)을 통해 영상의 흐름을 얻어 이 완성된 흐름을 기반으로 픽셀을 전파하여 손상된 영역을 채웠다.

Deep Video Inpainting [11]은 일시적인 특징 집합(temporal feature aggregation)과 시간적 일관성 보존(temporal consistency preserving)을 핵심 기능으로 가지는 ViNet이라는 모델을 제안했다. 이미지 기반의 인코더-디코더 모델을 기반으로 여러 개의 이웃 프레임들로부터 특징을 수집하여 이를 바탕으로 하나의 프레임의 누락된 영역을 채웠다. 또한 시간적인 일관성을 보존하기 위해 반복적인 피드백(recurrent feedback)을 통해 이전 단계의 출력값을 다음 단계의 입력값으로 주었고, 메모리 층을 추가하여 결과 프레임의 단기 및 장기 일관성을 보장했다.

이처럼 시각적으로 자연스러운 인페인팅 결과를 위한 계산법과 시공간적인 일관성을 보존하기 위한 모델에 관한 연구는 활발히 진행되고 있지만 인페인팅 데이터인 영상의 품질과 노이즈 제거 여부가 인페인팅 성능에 미치는 영향에 대해서는 거의 연구가 미미할 실정이다.

## III. 제안 기법

### 1. 제안 기법

본 논문에서 진행한 두 가지 실험은 다음과 같다.

- 실험 1. 노이즈가 포함된 프레임의 노이즈를 디노이징 기법으로 먼저 제거하고 인페인팅 한다.
- 실험 2. 노이즈가 포함된 프레임을 먼저 인페인팅 한 후 디노이징 기법으로 노이즈를 제거한다.

위 두 실험의 결과와 원본 프레임에 대한 인페인팅 결과를 비교하여 노이즈가 인페인팅 영상의 품질에 영향을 줄 수 있음을 확인한다. 또한 두 실험의 결과를 비교해 노이즈 제거 여부에 따른 인페인팅 성능을 비교하여 노이즈가 포함된 영상일 경우 노이즈 먼저 제거하는 것이 인페인팅 성능 향상에 도움이 될 수 있음을 제안한다.

### 2. 배경 기술

#### 2.1 Deep Flow-Guided Inpainting

본 실험에서는 비디오 인페인팅에 Deep Flow-Guided Video Inpainting 모델 [10]을 사용했다. 그림 1은 인페인팅 모델의 구조를 나타낸다. 전체 네트워크는 3개의 Deep Flow Completion Subnetwork (DFC-S)가 DFC-Net를 구성하고 있다. 각 DFC-S에서 추출한 영상 프레임 간 흐름(flow)을 기반으로 전체 영상의 흐름을 완성하고, 이 흐름(flow-file)을 양방향으로 전파해 프레임의 누락된 영역을 채운다. 원




그림 1. Deep Flow-Guided Video Inpainting 모델 구조  
Fig. 1. An Architecture of Video Inpainting Method




그림 2. Deep Flow-Guided Video Inpainting 입력 데이터  
Fig. 2. Input Images of Deep Flow-Guided Video Inpainting




그림 3. FastDVDnet 구조  
Fig. 3. An Architecture of FastDVDnet

본 모델의 흐름 추출에는 FlowNet2.0 [12] 모델이 사용되었지만, 본 실험에서는 전체 모델의 경량화를 위해 LiteFlowNet2.0 [13] 모델을 사용했다.

그림 2는 영상의 객체를 제거하기 위해 인페인팅 모델에 주어지는 입력의 예시다. 물체를 포함한 프레임과 물체의 위치를 나타내는 마스크가 입력으로 주어지면 DFC-Net은 프레임과 마스크가 겹치는 부분을 누락된 영역으로 인식하여 픽셀의 전파를 통해 마스크 영역을 배경과 유사하게 채운다.


### 2.2 FastDVDnet

프레임의 잡음 제거에는 Fast Deep Video Denoising Network (FastDVDnet) 모델 [14]을 사용했다. 그림 3은 FastDVDnet의 구조를 나타낸다. 이 네트워크는 영상의 흐름을 추출할 필요 없이 두 번의 노이즈 제거 단계를 거쳐 이미지의 노이즈를 제거한다. 전체 네트워크는 5장의 연속적인 입력 프레임과 표준편차가  $\sigma$ 인 노이즈맵을 입력값으로 가지며 첫 번째 디노이징 블록에는 3장의 입력 프레임과 노이즈맵이 입력으로 주어진다. 첫 번째 디노이징 단계를 구성하는 세 개의 디노이징 블록에서 각 1장의 노이즈 제거 프레임이 출력된다. 두 번째 디노이징 단계는 첫 번째 디노이징 단계에서 출력된 3장의 프레임을 입력값으로 가져 가운데 프레임의 노이즈를 제거하고 출력한다.


본 실험에서는 노이즈맵의 표준편차와 이미지에 추가한 노이즈의 표준편차를 5로 동일하게 설정하였으며 실험 방법에 따라 임의로 가우시안 노이즈를 추가한 원본 프레임 또는 노이즈를 추가한 후 인페인팅을 적용한 프레임을 입력값으로 주어 영상의 노이즈를 제거했다.

### 3. 데이터 세트

DAVIS 데이터 세트 (Densely Annotated Video Segmen-



Experiment 1. Inpaint frames after denoising



Experiment 2. Denoise frames after inpainting

그림 4. 제안 모델의 성능 평가를 위한 실험 방법  
Fig. 4. Experimental Methods for Evaluating Our Proposed Method

tation Dataset) [15]는 영상의 객체 분할 (Object Segmentation)을 위해 제안된 데이터 세트로 총 150개의 영상 데이터를 제공한다. 각 영상은 객체를 포함한 프레임과 그에 대한 주석 (Annotation)으로 구성되어 있다. 이 중 breakdance-floor, rollerblade, bmx-trees 데이터와 Deep Flow-Guided Video Inpainting 모델의 데모 버전에서 사용된 flamingo 영상에 대해 실험을 진행했다. 각 데이터 세트의 프레임에 노이즈를 넣거나 제거한 결과를 제안 기법의 입력 프레임으로 사용했으며 데이터세트의 객체 위치 정보를 가진 Annotation 데이터를 각 프레임의 이진 마스크 (Binary mask)로 입력했다.

### 4. 실험 방법

모든 실험 과정은 Ubuntu 환경에서 Python 3.7 버전, PyTorch 1.4.0 버전과 CUDA 11.3 버전으로 동일한 환경에서 진행되었다. 두 실험 모두 원본 비디오에 동일한 강도의 노이즈를 임의로 추가하여 실험을 진행했다. 원본 프레임에 추가한 노이즈는 가우시안 노이즈 (Gaussian noise)로 정규 분포를 따르며 평균이 0, 표준편차가 5인 노이즈를 생성하여 프레임에 추가했다. 그림 4는 두 가지 실험의 과정을 나타낸다. 첫 번째 실험은 노이즈를 추가한 각 프레임에 대해 먼저 FastDVDnet 모델을 사용해 노이즈를 제거하고 결과 프레임의 객체를 인페인팅했다. 두 번째 실험은 먼저 노이즈를 가진 프레임의 객체를 인페인팅 모델로 제거한 후 FastDVDnet 모델을 사용해 프레임의 노이즈를 제거했다.

## IV. 실험 결과

### 1. 정성 평가

그림 5~그림 8은 각기 다른 환경에서의 인페인팅 결과이다. 인페인팅을 적용하는 과정에서 단계별 프레임 출력값과 원본 프레임 대비 출력값의 Peak Signal-to-Noise Ratio 값



그림 5. 원본 프레임과 마스크에 대한 인페인팅 결과  
 Fig. 5. Inpainting Results of Original Frames and Masks




그림 6. 실험 1의 인페인팅 결과  
 Fig. 6. Inpainting Results of Experiment 1



(a) Noised frames (b) Denoised frames (c) Inpainting results

그림 7. 실험 2의 인페인팅 결과  
Fig. 7. Inpainting Results of Experiment 2



(a) Inpainting results of original frames (b) Inpainting results of experiment 1  
(c) Inpainting results of experiment 2

그림 8. 실험 1과 실험 2의 인페인팅 결과 비교  
Fig. 8. Comparison of Inpainting Results in Experiment 1 and Experiment 2

표 1. 두 실험에 대한 정량평가 및 비교 결과  
Table 1. Performance Comparison of Inpainting Results in Experiment 1 and Experiments 2

Dataset	Method	Evaluation metric	
		PSNR ↑	SSIM ↑
break dance	(a)	<b>23.645095</b>	<b>0.804672</b>
	(b)	23.367849	0.755008
flamingo	(a)	<b>21.008086</b>	<b>0.850027</b>
	(b)	20.861387	0.806348
rollerblade	(a)	<b>25.729382</b>	<b>0.877829</b>
	(b)	25.391393	0.862348
bmx-trees	(a)	<b>28.524588</b>	<b>0.899922</b>
	(b)	28.142090	0.888364
(a) Experiment 1 : Denoising → Inpainting			
(b) Experiment 2 : Inpainting → Denoising			

을 담고 있다. 그림 5는 노이즈를 추가하지 않은 원본 프레임에 대한 인페인팅 결과다. 각 데이터 별로 마스크 영역의 객체가 제거된 결과를 확인할 수 있다. 그림 6은 실험 1의 결과다. 단계별로 노이즈를 넣은 프레임, 노이즈를 제거한 프레임, 인페인팅 결과가 순서대로 담겨있다. 그림 7은 실험 2의 결과로 노이즈를 넣은 프레임, 인페인팅 결과, 노이즈를 제거한 결과를 순서대로 나타냈다.

그림 8은 위에서부터 차례로 (a) 원본 프레임의 인페인팅 결과, (b) 실험 1의 결과, (c) 실험 2의 결과를 객체가 있던 부분 중심으로 확대한 사진이다. (a)의 결과에 비해 (b), (c)의 결과는 노이즈 제거 작업으로 인해 사진의 질감 (texture)이 부족함을 확인할 수 있다. (b)와 (c)를 비교해보면 대체적으로 노이즈 제거 작업을 먼저 수행한 (b)에 비해 인페인팅 후 노이즈를 제거한 (c)의 노이즈가 제대로 제거되지 않아 영상이 부자연스러운 것처럼 보인다.

## 2. 정량 평가

표 1은 앞서 수행한 실험 1, 2의 결과를 각각 DAVIS dataset의 원본 프레임과 비교한 정량적 평가값을 담고 있다. 평가 결과에 따르면 인페인팅 후 노이즈를 제거했던 실험 (b)보다 노이즈를 제거하고 인페인팅을 적용했던 실험 (a)가 Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM) 값에 대해 더 높은 성능을 보였다.

## V. 결론

본 논문에서는 잡음이 포함된 영상의 잡음 제거 여부가 인페인팅 기술에 미치는 영향에 대해 실험을 통해 비교해 보았다. 앞서 진행한 두 실험을 비교해 봤을 때, 노이즈가 포함된 영상을 인페인팅한 후 노이즈를 제거한 영상은 노이즈가 완벽하게 제거되지 않았다. 반면에 노이즈를 제거한 후 인페인팅을 적용한 영상은 노이즈가 비교적 깨끗하게 제거되

어 앞의 실험 결과보다 자연스러운 것을 확인했다. 이는 노이즈가 포함된 프레임을 인페인팅할 경우 노이즈가 포함된 픽셀 정보를 통해 빈 영역을 채웠기 때문에 노이즈가 완벽히 제거되지 않은 것으로 추측된다. 이 실험 결과를 통해 잡음 제거 여부가 인페인팅 결과에 영향을 미칠 수 있으며, 영상에 노이즈가 존재하는 경우 먼저 노이즈를 제거한 후 인페인팅을 진행하는 것이 비디오의 품질을 개선할 가능성이 있음을 알 수 있다. 본 제안 기법을 실제 야간에 촬영된 영상이나 의도치 않게 노이즈가 발생한 영상에 적용한다면 실제 인페인팅 기술의 품질을 높이는 데 도움이 될 것으로 기대된다. 향후 본 실험을 확장시켜 다른 데이터셋에 적용해 보고 다양한 인페인팅 모델과 노이즈 제거 모델을 사용하여 추가 연구를 진행할 예정이다.

## References

- [1] M. Bertalmio, L. Vese, G. Sapiro, S. Osher, "Simultaneous Structure and Texture Image Inpainting," *IEEE Transactions on Image Processing*, Vol. 12, No. 8, pp. 882–889, 2003.
- [2] S. Darabi, E. Shechtman, C. Barnes, D. Goldman, P. Sen, "Image Modeling: Combining Inconsistent Images Using Patch-based Synthesis," *ACM Transactions on Graphics*, Vol. 31, No. 4, Art. 82, pp. 1–10, 2012.
- [3] M. Bertalmio, G. Sapiro, V. Caselles, C. Ballester, "Image Inpainting," *Proceedings of the 27th Annual Conference on Computer Graphics and Interactive Techniques*, pp. 417–424, 2000.
- [4] C. Ballester, M. Bertalmio, V. Caselles, G. Sapiro, J. Verder, "Filling-in by Joint Interpolation of Vector Fields and Gray Levels," *IEEE Transactions on Image Processing*, Vol. 10, No. 8, pp. 1200–1211, 2001.
- [5] G. Liu, F. A. Reda, K. J. Shih, T. C. Wang, A. Tao, B. Catanzaro, "Image Inpainting for Irregular Holes Using Partial Convolutions," *Proceedings of the European Conference on Computer Vision*, pp. 85–100, 2018.
- [6] J. Yu, Z. Lin, J. Yang, X. Shen, X. Lu, T. Huang, "Free-form Image Inpainting with Gated Convolution," *Proceedings of IEEE/CVF International Conference on Computer Vision*, pp. 4470–4479, 2019.
- [7] S. Iizuka, E. Simo-Serra, H. Ishikawa, "Globally and Locally Consistent Image Completion," *ACM Transactions on Graphics*, Vol. 36, No. 4, pp. 1–14, 2017.
- [8] J. Yu, J. Yang, X. Shen, X. Lu, T. S. Huang, "Generative Image Inpainting with Contextual Attention," *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 5505–5514, 2018.
- [9] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, "Generative Adversarial Nets," *Advances in Neural Information Processing Systems*, pp. 2672–2680, 2014.
- [10] R. Xu, X. Li, B. Zhou, C.C. Loy, "Deep Flow-guided Video Inpainting," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*,

pp. 3718-3727, 2017.

[11] D. Kim, S. Woo, J. Y. Lee, I. S. Kweon, "Deep Video Inpainting," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 5792-5801, 2019.

[12] E. Ilg, N. Mayer, T. Saikia, M. Keuper, A. Dosovitskiy, T. Brox, "FlowNet 2.0: Evolution of Optical Flow Estimation with Deep Networks." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2462-2470, 2017.

[13] T. W. Hui, X. Tang, C. C. Loy, "LiteFlowNet: A Lightweight Convolutional Neural Network for Optical Flow Estimation," Proceedings of the IEEE Conference

on Computer Vision and Pattern Recognition, pp. 8981-8989, 2018.

[14] M. Tassano, J. Delon, T. Veit, "FastDVDnet: Towards Real-time Deep Video Denoising Without Flow Estimation," Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 1351-1360, 2020.

[15] F. Perazzi, J. Pont-Tuset, B. McWilliams, L. V. Gool, M. Gross, A. Sorkine-Hornung, "A Benchmark Dataset and Evaluation Methodology for Video Object Segmentation," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 724-732, 2016.

**Jeong-yun Seo (서 정 윤)**



2019~Computer Science and Engineering from Kyungpook National University (B.S.)

Field of Interests: Deep Learning, Computer Vision, Inpainting  
Email: yooniverse@knu.ac.kr

**Han-gyul Baek (백 한 결)**



2021 Electrical and Computer Engineering from Daejeon University (B.S.)  
2021~Computer Science and Engineering from Kyungpook National University (M.S.)

Field of Interests: Deep Learning, Computer Vision, Inpainting  
Email: qorgksruffl23@knu.ac.kr

**Sang-hyo Park (박 상 효)**



2011 Computer Engineering from Hanyang University (B.S.)  
2017 Computer Science from Hanyang University (Ph.D.)

Career:

2017~2018 Postdoctoral position, Korea Electronics Technology Institute (KETI)

2018 Research Fellow, Yonsei University

2019~2020 Postdoctoral position, Ewha Womans University

2020~Assistant Professor with the School of Computer Science and Engineering, Kyungpook National University

Field of Interests: VVC, encoding complexity, immersive video, model optimization

Email: s.park@knu.ac.kr