

실시간 영상 초해상도 복원을 위한 효율적인 신경망 구조 연구[☆]

Study of Efficient Network Structure for Real-time Image Super-Resolution

정 우 진¹ 한 복 규¹ 이 동 석² 최 병 인² 문 영 식^{1*}
Woojin Jeong Bok Gyu Han Dong Seok Lee Byung In Choi Young Shik Moon

요 약

단일 영상 초해상도는 하나의 저해상도 영상에서 고해상도 영상을 복원하는 과정이다. 최근 심층신경망을 적용한 초해상도 기법이 좋은 성과를 나타내고 있다. 본 논문에서는 기존의 심층신경망 기반 초해상도 복원 기법보다 속도와 성능을 개선한 신경망 구조를 제안한다. 이를 위해 기존 기법의 단점을 분석하고 해결책을 제시한다. 제안하는 방법은 기존 기법의 5단계를 3단계로 줄여 효율성을 높였으며, 네트워크의 폭과 깊이에 대한 실험을 통해 가장 효율적인 신경망 구조를 연구하였다. 제안하는 방법의 성능과 속도를 알아보기 위해 비교 실험을 진행하였다. 제안하는 방법은 1024×1024 영상을 초당 148장 복원하는 속도를 나타냈으며, 4가지 데이터에 대해 기존 방법보다 복원 성능이 우수하였다.

☞ 주제어 : 영상 초해상도 복원, 심층신경망, 컨볼루션 신경망

ABSTRACT

A single-image super-resolution is a process of restoring a high-resolution image from a low-resolution image. Recently, the super-resolution using the deep neural network has shown good results. In this paper, we propose a neural network structure that improves speed and performance over conventional neural network based super-resolution methods. To do this, we analyze the conventional neural network based super-resolution methods and propose solutions. The proposed method reduce the 5 stages of the conventional method to 3 stages. Then we have studied the optimal width and depth by experimenting on the width and depth of the network. Experimental results have shown that the proposed method improves the disadvantages of the conventional methods. The proposed neural network structure showed superior performance and speed than the conventional method.

☞ keyword : Image super-resolution, deep neural network, convolutional neural network

1. 서 론

단일 영상 초해상도 (single image super-resolution: SISR)는 하나의 저해상도 (low-resolution: LR) 영상에서 고해상도 (high-resolution: HR) 영상을 복원하는 과정이다. 전통적으로 많은 연구가 있었으나, 최근에는 패턴인식과 기계학습을 이용하여 LR-HR 패치 쌍을 학습하는 방법이 좋은 성능을 나타냈다. 대표적으로 사전 학습 방법 [1][2], 국부 선형 회귀 [3][4], 임의숲 (random forest) [5] 등의 방법이 연구되었다.

최근에는 심층신경망 (deep neural network) 기술이 발

견하여 다양한 분야에서 우수한 성능을 나타내고 있다. SISR 분야 또한 심층신경망 기술을 적용하여 높은 성능을 나타내었다. 심층신경망 기술을 이용한 SISR의 가장 이른 연구 중 하나는 SRCNN (super-resolution convolutional neural network) [6]이다. SRCNN은 단순한 3층의 컨볼루션 신경망 (convolutional neural network)을 사용하는 SISR로, 기존의 심층신경망 기술이 아닌 기존 SISR 방법보다 우수한 성능을 나타냈다. 이후 SRCNN의 속도를 개선한 FSRCNN (fast super-resolution convolutional neural network) [7]이 제안되었다. FSRCNN은 5단계의 과정을 거쳐 HR영상을 복원한다. 1) feature extraction: 입력 영상으로부터 LR 특징을 추출하는 단계로 5×5크기의 커널로 56개 특징지도 (feature map)를 만든다. 2) encoding: 56개의 LR 특징지도를 12개의 특징지도로 압축하는 단계로 1×1 컨볼루션을 사용, 이를 통해 inference 단계의 연산 부하를 줄인다. 3) inference: LR 특징으로부터 HR 특징을 추론하는 단계로 3×3 컨볼루션 4개 층으로 구성된다. 4)

1 Department of computer science and engineering, Hanyang University, Ansan, 15588, Korea.

2 Image PGM Team, Hanwha Systems, Gumi, 39376, Korea

* Corresponding author (ysmoon@hanyang.ac.kr)

[Received 18 May 2018, Reviewed 26 May 2018, Accepted 12 June 2018]

☆ 이 연구는 (주)한화시스템의 지원을 받아 연구되었습니다.

decoding: 12개의 특징지도를 56개로 압축해제 하는 단계로 1×1 컨볼루션을 사용한다. 5) restoration: 영상복원 단계로 9×9 컨볼루션 전치 층 (convolution transpose layer)으로 구성된다. FSRCNN은 inference 단계의 특징지도 크기를 12로 줄여 SRCNN 보다 빠른 SISR을 구현하였다. 대신 신경망의 깊이는 SRCNN의 3보다 깊은 8로 늘려서 복원성능도 향상시켰다.

본 논문에서는 FSRCNN 보다 복원성능은 더 우수하지만 동일한 수준의 속도로 영상을 복원하는 SISR 신경망을 제안한다. FSRCNN은 우수한 복원품질과 복원속도를 나타냈지만 구조를 최적화 하여 더 우수한 결과를 얻을 수 있다. 깊이가 8로 심층신경망 중에서는 않지만, SISR을 위한 최소 깊이인 3보다는 깊다. 따라서 깊이를 줄여 속도를 개선할 수 있다. 또한 깊이와 폭의 적정 조정을 탐색하면 FSRCNN보다 우수하면서 빠른 네트워크를 구성할 수 있다. 마지막으로 FSRCNN의 restoration 단계는 결과영상과 동일한 해상도에서 컨볼루션 연산을 수행한다. pixel shuffler를 사용하여 더 낮은 해상도에서 restoration 단계를 수행 할 수 있다.

본 논문의 기여는 다음과 같다. 1) FSRCNN의 단점을 분석하고 개선 방향을 논의하였다. 2) 다양한 신경망 구조를 실험하여 빠르면서도 우수한 SISR 신경망 구조 제시 하였다. 3) 제안하는 SISR 신경망 구조를 실험을 통해 다른 방법과 비교하였다.

본 논문의 이후 구성을 간략하게 설명하면 다음과 같다. 2장에서는 기계학습, 심층신경망 기반 SISR 연구를 살펴본다. 3장에서는 제안하는 SISR 구조를 설명한다. 4장에서는 다양한 신경망 구조에 대한 실험, 제안하는 신경망과 다른 방법의 비교 실험한다. 5장은 결론이다.

2. 관련 연구

급속히 발전한 기계학습 기반 방법 그리고 심층신경망 기반 방법들은 다양한 연구 분야에서 우수한 성과를 거두고 있으며 SISR 분야에서도 큰 영향을 끼치고 있다. 이에 관련 연구에서는 기계학습, 심층신경망 기반 SISR 방법들을 살펴본다.

2.1 기계학습 기반 초해상도 복원 연구

기계학습 기반으로 LR-HR 쌍을 학습하는 방법들은 앞선 방법보다 우수한 성능을 보였다. 기계학습 기반 방법들은, 입력 영상만으로 HR을 복원하는 방법과 입력영상

이외의 외부영상을 활용하는 방법으로 나뉜다.

자연 영상에 존재하는 자기 유사성과 입력 영상의 공간 피라미드를 이용한 복원방법 [8][9], 패치를 각 방향의 주파수에 따라 서브 밴드로 분해하고 각각의 서브 밴드에서 HR 패치를 찾는 방법 [10], 영상변환 (image transform)으로 패치를 변형하여 학습공간을 확장하는 방법 [11] 등이 입력영상만 이용하는 방법으로 제안되었다. 입력영상만 이용하는 방법은 단일영상만으로 영상을 복원하기 때문에 다양한 분야에서 활용될 수 있으나, 올바른 LR-HR 쌍을 찾지 못하거나, 계산량이 크게 증가하는 문제가 있다. 이 문제는 외부영상을 활용하여 해결 할 수 있다.

외부영상을 활용하는 방법은 대규모 외부영상을 사전에 학습하며 이때 LR-HR 쌍을 구성하는 방법에 대한 연구가 진행되었다. 희소 사전 (sparse dictionary)을 사용하는 방법 [1][2], 국부 선형 회귀를 이용하는 방법 [3][4], 임의 숲을 사용하는 방법 [5] 등이 제안되었다.

2.2 심층신경망 기반 초해상도 복원 연구

심층신경망 기술은 다양한 분야에서 우수한 성과를 거두었으며, 이에 따라 SISR에서도 심층신경망을 이용한 방법이 시도되고 있다. SRCNN [6]은 가장 이른 심층신경망 기반의 SISR 연구 중 하나이다. SRCNN은 단순한 3층의 컨볼루션 신경망으로 SISR을 수행하였으며 기존의 방법보다 우수한 성능을 나타냈다. 이후 심층신경망 기반 SISR 연구는 3가지 분야로 진행되고 있다.

첫 번째 분야는 신경망의 크기에 상관없이 우수한 복원품질을 연구하는 분야이다. 이 분야의 연구목표는 정답 HR과 가장 유사한 HR영상을 복원하는 것이다. 매우 깊은 초해상도 복원 신경망 [12], 깊고 반복적인 구조를 사용하며 컨볼루션 층의 파라미터를 공유하는 신경망 [13] 등이 제안되었다.

두 번째는 실 사진과 같은 (photo-realistic) 영상을 복원하는 분야이다. 이 분야의 목표는 복원된 영상이 마치 본래부터 고해상도 영상인 것처럼 인간을 속이는 것이다. 따라서 정답영상과 비슷하지 않을 수 있다. 대표적으로 generative adversarial networks를 이용해 영상을 복원하는 SRGAN (super-resolution generative adversarial network) [14] 이 제안되었다.

세 번째는 제한된 환경에서 우수한 SISR 신경망 구조를 연구하는 분야이다. 일반적으로 신경망이 거대할수록 우수한 성능을 나타낸다. 세 번째 분야는 복원 속도, 신경

망의 크기를 제한하여 우수한 신경망 구조를 연구한다. 대표적으로 FSRCNN [7]이 제안되었다.

3. 제안하는 신경망 구조

FSRCNN은 작은 네트워크 크기만큼 영상 복원 속도가 우수하였다. 동시에 속도에 비해 우수한 복원 품질을 나타냈다. 그러나 네트워크의 일부는 개선이 가능하다. 이 장에서는 FSRCNN의 문제점을 분석하고 해결책을 제시한다.

3.1 암시적인 Encoding-Decoding 구조

FSRCNN은 1×1 컨볼루션으로 특징지도를 압축한다. 이는 네트워크의 효율성을 높이는 장점이 있지만 동시에 encoding과 decoding을 위해 2개 층이 필요하다. 본 연구에서는 encoding, decoding 단계를 inference, restoration 단계에 암시적으로 포함하여 2개 층을 줄인다. 2개 층이 줄어들면 속도는 향상된다. 4장에서 관련된 실험으로 1×1 컨볼루션 없이도 충분히 특징지도를 압축하거나 해제할 수 있음을 보였다.

3.2 네트워크의 폭과 깊이 조정

일반적으로 깊은 네트워크는 더 우수한 성능을 나타내는 것으로 알려져 있다 [15][16]. 그러나 다른 연구에서는 깊이 뿐 아니라 폭도 중요한 요소라고 반박하였다 [17]. 또한 [17]에서 폭이 넓은 구조는 수행 속도면에서 많은 이득이 있다고 하였다. 이에 본 연구에서는 폭과 깊이의 균형을 탐색하였다.

FSRCNN은 깊이가 총 8개 층이며, inference 단계에서 12채널의 폭을 갖는다. 본 연구에서는 FSRCNN의 폭과 깊이의 조정을 통해 보다 우수하며 빠른 구조를 탐구하고 관련 실험을 통해 더 나은 구조를 제시한다. 속도를 증가시키기 위해 전체 네트워크의 깊이는 줄였으며, 줄어든 성능을 보완하기 위해 inference 단계의 폭은 늘렸다. 4장에서 관련된 실험을 통해 제안하는 구조가 FSRCNN보다 적절한 네트워크 폭과 깊이라는 것을 보였다.

3.3 Pixel Shuffler를 이용하여 낮은 해상도에서 영상을 복원

심층신경망에서 특징지도를 확대하거나 축소하는 많은 방법이 있다 [18]. 이 중 pixel shuffler는 단순한 재배치

(표 1) 제안하는 네트워크 구조

(Table 1) The proposed network structure

단계	연산	특징지도 크기
Input		H×W×1
Feature Extraction	Conv. (5×5)	H×W×64
Inference	Conv. (3×3)	H×W×32
	Conv. (3×3)	H×W×32
	Conv. (3×3)	H×W×32
Restoration	Pixel Shuffler	2H×2W×8
	Conv. (3×3)	2H×2W×4
	Pixel Shuffler	4H×4W×1
Output		4H×4W×1

(표 2) FSRCNN 네트워크 구조

(Table 2) FSRCNN network structure

단계	연산	특징지도 크기
Input		H×W×1
Feature Extraction	Conv. (5×5)	H×W×56
Encoding	Conv. (1×1)	H×W×12
Inference	Conv. (3×3)	H×W×12
	Conv. (3×3)	H×W×12
	Conv. (3×3)	H×W×12
	Conv. (3×3)	H×W×12
Decoding	Conv. (1×1)	H×W×56
Restoration	Conv. Transpose (9×9)	4H×4W×1
Output		4H×4W×1

를 통해 특징지도의 크기를 변경한다. 따라서 속도가 빠른 장점이 있다.

FSRCNN은 높은 해상도에서 restoration 단계를 수행한다. 본 연구에서는 낮은 해상도에서 영상을 복원한 뒤 pixel shuffler를 이용해 영상을 확대하는 방법을 사용한다. 낮은 해상도에서 영상을 복원하기 때문에, 다시 말해 작은 특징지도에 컨볼루션을 수행하기 때문에 제안하는 구조가 FSRCNN보다 빠르게 영상을 복원한다. 4장에서 관련된 실험을 통해 제안하는 구조가 FSRCNN보다 우수한 restoration 단계를 구성했음을 보였다. 구현은 TensorFlow의 depth_to_space 함수를 사용하였다.

3.4 제안하는 네트워크 구조

앞선 분석과 실험을 바탕으로 네트워크 구조를 제안한다. 제안하는 구조는 FSRCNN보다 더 빠르게 영상을 복원하면서도 복원 품질은 더 우수하다. 표 1은 제안하는 네트워크의 구조이다. 제안하는 구조는 3단계로 구성된다. 1) feature extraction: 이 단계는 FSRCNN의 그것과 같은 역할을 수행한다. 5×5 컨볼루션으로 64개의 특징지도를 만든다. 2) inference: 이 단계는 FSRCNN의 encoding 단계, inference 단계와 같은 역할을 수행한다. 3×3 컨볼루션층 3개로 이루어지며, 특징지도 개수는 32이다. FSRCNN보다 많은 특징지도를 사용하되, encoding, inference 단계를 합쳐 깊이는 줄였다. 3) restoration: 이 단계는 FSRCNN의 decoding 단계, restoration 단계와 같은 역할을 수행한다. 4배 확대를 기준으로 pixel shuffler, 3×3 컨볼루션, pixel shuffler가 순서대로 배치된다. 첫 번째 pixel shuffler에서는 H×W×32 크기의 특징지도를 2H×2W×8 크기로 바꾼다. 가운데 컨볼루션층에서는 특징지도 크기를 2H×2W×4로 바꾼다. 마지막 pixel shuffler에서는 특징지도 크기를 4H×4W×1로 바꾼다. 특징지도 크기가 2H×2W일 때 컨볼루션 연산을 수행하기 때문에 FSRCNN에 비해 속도가 빠르다. 같은 논리를 적용할 때 FSRCNN은 4H×4W일 때 복원을 위한 컨볼루션 연산을 한다.

4. 실험과 분석

실험을 통해 다양한 신경망 구조를 분석하고 우수한 SISR 구조를 제안한다. 또한 제안하는 신경망을 다른 SISR 방법과 비교한다.

4.1 실험 상세

실험 데이터는 Set5 [19], Set14 [20], BSD100 [21], DIV2K [22]를 사용하였다. 정량적 비교는 Bicubic, A+ [3], SRCNN [6], FSRCNN [7]과 비교하였다.

실험에 사용된 컴퓨터의 하드웨어는 Intel i5-6600 2.6GHz, 48GB RAM, GTX 1080 Ti이며 소프트웨어는 windows7, python 3.5, TensorFlow 1.3을 사용하였다. 훈련 데이터는 DIV2K의 훈련데이터를 사용하였고 매 배치(batch) 마다 임의의 영상에서 임의 위치의 64×64크기의 패치를 128개 사용하였다. 3,072,000 배치 학습 후 학습을 종료하였다. 학습 알고리즘은 Adam optimizer [23]를 사용하였고, 초기 학습률은 0.001이다.

4.2 실험 1: 개선과정

이 절에서는 FSRCNN을 조금씩 바뀌며 성능 개선 여부를 살펴보았다. 표 3은 FSRCNN에서부터 제안하는 구조로 바뀌는 과정과 그 때의 성능, 속도를 나타낸다. 성능은 Set5데이터를 4배 확대할 때 PSNR로 측정하였고, 복원속도는 512×512 LR 영상을 4배 확대하여 2048×2048 HR 영상으로 만들 때 평균 fps (frame per second)를 측정하였다. 올바른 비교를 위해 FSRCNN의 속도는 직접 측정하였다. FSRCNN보다 우수한 경우 음영으로 표시하였다. 표 3(a)는 FSRCNN과 동일하다. 표 3(b)에서 inference 단계의 깊이를 절반으로 줄였을 때 복원성능은 감소하였지만 복원속도는 향상되었다. 표 3(c)에서 inference 폭을 증가시키자 FSRCNN에 비해 복원성능은 좋아졌지만, 복원속도는 비슷하였다. 표 3(d), (e)에서 암시적 encoding-decoding, pixel shuffler를 적용함에 따라 복원속도는 향상되었지만 복원성능은 감소하였다. 마지막 표 3(f)에서 inference 단계의 깊이를 3으로 늘렸을 때 복원속도, 복원성능 모두

(표 3) 네트워크 변화에 따른 성능 변화

(Table 3) Performance changes due to network structure changes

이름	구성					PSNR (dB)	평균속도 (fps)
	inference 깊이	inference 폭	암시적 encoding decoding	pixel shuffler	총 깊이		
(a) FSRCNN	4	12			8	30.70	46.45
(b)	2	12			6	30.28	48.56
(c)	2	32			6	30.74	46.24
(d)	2	32	⊙		4	30.66	50.47
(e)	2	32	⊙	⊙	4	30.62	49.31
(f) 제안하는 방법	3	32	⊙	⊙	5	30.82	46.79

(표 4) 네트워크 폭과 깊이 변화에 따른 성능 변화

(Table 4) Performance changes due to width and depth of network structure changes

inference의 폭	평가항목	inference의 깊이							
		2	3	4	5	6	7	8	9
8	PSNR (dB)	29.58	29.92	30.09	30.08	30.01	30.12	30.23	30.34
	속도 (fps)	56.75	54.79	53.42	51.14	50.47	48.91	47.34	45.77
16	PSNR (dB)	30.21	30.29	30.32	30.47	30.55	30.64	30.73	30.81
	속도 (fps)	54.79	52.98	50.88	48.93	47.84	46.10	44.36	42.62
32	PSNR (dB)	30.57	30.82	30.92	31.03	31.04	-	-	-
	속도 (fps)	49.69	46.79	43.91	41.36	39.09	-	-	-

(표 5) 복원 성능 비교

(Table 5) Restoration performance comparison

Method	Set5		Set14		BSD100		DIV2K	
	PNSR (dB)	SSIM	PNSR (dB)	SSIM	PNSR (dB)	SSIM	PNSR (dB)	SSIM
Bicubic	28.42	0.810	25.99	0.702	25.96	0.667	28.09	0.773
A+ [3]	30.23	0.860	27.24	0.748	26.81	0.708	29.23	0.807
SRCNN [6]	30.48	0.862	27.48	0.751	26.90	0.710	29.34	0.809
FSRCNN [7]	30.70	0.865	27.57	0.754	26.97	0.713	29.44	0.811
제안하는 방법	30.82	0.873	27.64	0.759	27.04	0.719	29.47	0.815

FSRCNN 보다 우수하였다. 본 실험을 통해 신경망 깊이 감소, 암시적 encoding-decoding 사용, pixel shuffler의 사용은 복원속도는 향상시키되 복원성능은 감소시킨다는 것을 확인하였다. 반대로 넓이증가는 복원성능은 향상시키되 복원속도는 감소시킨다는 것을 확인하였다. 다양한 신경망 구조 실험을 통해 FSRCNN보다 빠르고 우수한 구조를 발견하였다.

4.3 실험 2: 네트워크의 폭, 깊이 실험

실험 1을 바탕으로 inference 단계의 폭과 깊이를 바꿔가며 실험을 하였다. 표 4는 실험결과이다. 음영이 표현된 칸은 FSRCNN대비 우수한 경우이다. 32폭의 7, 8, 9깊이는 실험하지 않았다. 대체로 깊을수록, 넓을수록 좋은 성능을 나타냈지만 수행속도는 감소하였다. 32폭에 3깊이인 경우 PSNR과 속도 모두 FSRCNN보다 우수하였다.

4.4 실험 3: 다른 방법과 복원 성능 비교

이 절에서는 제안하는 구조와 기존 방법의 결과를 비교한다. 표 5는 복원 성능 비교이다. 모두 4배 확대하는 경우의 PSNR (peak signal-to-noise ratio) 과 SSIM (structural similarity) 을 기록하였다. 각 데이터에 대한 결과 중 가장 우수한 경우 **진하게**, **밑줄**로 표시하였고, 그

다음 우수한 경우 **이탤릭**, **밑줄**로 표시하였다. 실험한 모든 데이터에 대해 제안하는 방법이 기존 방법보다 우수한 복원 성능을 나타냈다. FSRCNN과 가장 격차가 큰 경우는 Set5 데이터로 PSNR 0.12dB, SSIM 0.008 차이였고 작은 경우는 DIV2K로 0.03dB, SSIM 0.004 이었다. 모든 데이터에 대해 제안하는 방법이 다른 방법에 비해 모두 우수하다는 것은 제안하는 방법의 복원성능이 일정하게 우수하다는 것을 나타낸다.

4.5 실험 4: 다른 방법과 복원 속도 비교

제안하는 방법의 복원 속도를 비교하였다. 표 6은 복원에 걸리는 시간을 나타낸다. 실험 조건은 4.2 절과 동일

(표 6) 복원 속도 비교

(Table 6) Restoration speed comparison

Method	Restoration speed (fps)	
	(LR size → HR size)	
	256 → 1024	512 → 2048
Bicubic	411.12	120.74
A+ [3]	0.54	0.13
SRCNN [7]	4.43	1.19
FSRCNN [6]	143.58	46.45
제안하는 방법	148.59	46.79

하다. 모두 4배 확대하는 경우이며 크기가 256×256 LR 영상을 1024×1024 HR로, 512×512 LR 영상을 2048×2048 HR 영상으로 확대하는 경우를 측정하였다. Bicubic 방법은 단순한 보간 방법이기 때문에 가장 빠른 복원 속도를 나타냈다. Bicubic을 제외하고는 제안하는 방법이 가장 빠른 복원 속도를 나타냈다. FSRCNN과 제안하는 방법은 256→1024 인 경우 140 fps를 넘고, 512→2048인 경우에도 46 fps를 넘어 실시간 영상처리가 가능한 수준이었다. 두가지 방법 중에서는 약간의 차이지만 제안하는 방법이 더 빠르게 영상을 복원하였다.

4.6 실험 결론

실험을 통해 기존 방법보다 우수한 복원성과 빠른 복원속도를 갖는 초해상도 복원 구조를 탐색하였다. 그리고 최적의 네트워크 구조를 제안하였다. 기존 방법의 비교했을 때 제안하는 방법은 복원성능은 일관되게 우수하였으며 복원속도 또한 빨랐다. 이는 제안하는 방법의 네트워크 구조가 기존 방법의 네트워크 구조보다 우수하기 때문으로 분석된다.

5. 결 론

본 논문에서 속도와 복원 성능 모두 우수한 초해상도 복원 기법을 제시하였다. 제안하는 방법은 심층신경망 기반의 방법으로 기존의 FSRCNN의 단점을 개선하였다. 실험을 통해 FSRCNN의 단점이 개선되는 과정을 보였으며, 이를 통해 최적의 구조를 제안하였다. 제안하는 방법은 다른 방법과 비교 결과 빠르면서도 우수하게 영상을 복원하였다.

참고문헌(Reference)

- [1] J. Yang, J. Wright, T. Huang, and Y. Ma, "Image super-resolution as sparse representation of raw image patches," in IEEE Conference on Computer Vision and Pattern Recognition, June 2008.
<https://doi.org/10.1109/CVPR.2008.4587647>
- [2] J. Yang, J. Wright, T. Huang, and Y. Ma, "Image super-resolution via sparse representation," IEEE Transactions on Image Processing, Vol. 19, No. 11, pp.2861-2873, 2010.
<https://doi.org/10.1109/TIP.2010.2050625>
- [3] R. Timofte, V. D. Smet, and L. V. Gool, "A+: Adjusted anchored neighborhood regression for fast super-resolution," in Asian Conference on Computer Vision, Nov. 2014.
https://doi.org/10.1007/978-3-319-16817-3_8
- [4] C. Y. Yang and M. H. Yang, "Fast direct super-resolution by simple functions," in IEEE Conference on Computer Vision and Pattern Recognition, Dec. 2013.
<https://doi.org/10.1109/ICCV.2013.75>
- [5] S. Schuler, C. Leistner, and H. Bischof, "Fast and accurate image upscaling with super-resolution forests," in IEEE Conference on Computer Vision and Pattern Recognition, June 2015.
<https://doi.org/10.1109/CVPR.2015.7299003>
- [6] C. Dong, C. C. Loy, K. He, and X. Tang, "Image super-resolution using deep convolutional networks," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 38, No. 2, pp295-307, 2015.
- [7] C. Dong, C. C. Loy, and X. Tang, "Accelerating the Super-Resolution Convolutional Neural Network," in European Conference on Computer Vision, pp.391-407, 2016.
https://doi.org/10.1007/978-3-319-46475-6_25
- [8] G. Freedman and R. Fattal, "Image and video upscaling from local self-examples," ACM Transactions on Graphics, Vol. 30, No. 2, 2011.
<https://doi.org/10.1063/1.4993002>
- [9] D. Glasner, S. Bagon, and M. Irani, "Super-resolution from a single image," in IEEE International Conference on Computer Vision, Sept. 2009.
<https://doi.org/10.1145/1944846.1944852>
- [10] A. Singh and N. Ahuja, "Super-resolution using sub-band self-similarity," in Asian Conference on Computer Vision, Nov. 2014.
https://doi.org/10.1007/978-3-319-16808-1_37
- [11] J.-B. Huang, A. Singh, and N. Ahuja, "Single image super-resolution from transformed self-exemplars," in IEEE Conference on Computer Vision and Pattern Recognition, June 2015.
<https://doi.org/10.1109/CVPR.2015.7299156>
- [12] J. Kim, J. K. Lee, and K. M. Lee, "Accurate image super-resolution using very deep convolutional networks," in IEEE Conference on Computer Vision

- and Pattern Recognition, June 2016.
<https://doi.org/10.1109/CVPR.2016.182>
- [13] J. Kim, J. K. Lee, and K. M. Lee, "Deeply-Recursive Convolutional Network for Image Super-Resolution," in IEEE Conference on Computer Vision and Pattern Recognition, June 2016.
<https://doi.org/10.1109/CVPR.2016.181>
- [14] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz, Z. Wang, and W. Shi, "Photo-realistic single image super-resolution using a generative adversarial network," in IEEE Conference on Computer Vision and Pattern Recognition, July 2017.
<https://doi.org/10.1109/CVPR.2017.19>
- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in IEEE Conference on Computer Vision and Pattern Recognition, 2016.
<https://doi.org/10.1109/CVPR.2016.90>
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Identity Mappings in Deep Residual Networks," in European Conference on Computer Vision, 2016.
https://doi.org/10.1007/978-3-319-46493-0_38
- [17] S. Zagoruyko and N. Komodakis, "Wide Residual Networks," in Proceedings of the British Machine Vision Conference, pp.87.1-87.12. Sept.2016.
<https://dx.doi.org/10.5244/C.30.87>
- [18] Z. Wojna, V. Ferrari, S. Guadarrama, N. Silberman, L.-C. Chen, A. Fathi, and J. Uijlings, "The Devil is in the Decoder," arXiv preprint, arXiv:1707.05847, 2017.
<https://arxiv.org/abs/1707.05847>
- [19] M. Bevilacqua, A. Roumy, C. Guillemot, and M. L. Alberi-Morel, "Low-complexity single-image super-resolution based on nonnegative neighbor embedding," in Proceedings of the 23rd British Machine Vision Conference, Sept. 2012.
<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.297.1474>
- [20] R. Zeyde, M. Elad, and M. Protter, "On single image scale-up using sparse-representations," in International Conference on Curves and Surfaces. June 2010.
https://doi.org/10.1007/978-3-642-27413-8_47
- [21] P. Arbelaez, M. Maire, C. Fowlkes, and J. Malik, "Contour detection and hierarchical image segmentation," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 33, No. 5, pp.898-916, 2011.
<https://doi.org/10.1109/TPAMI.2010.161>
- [22] E. Agustsson and R. Timofte "NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study," in IEEE Conference on Computer Vision and Pattern Recognition Workshops, July, 2017.
<http://doi.org/10.1109/CVPRW.2017.150>
- [23] Diederik P. Kingma, Jimmy Ba, "Adam: A Method for Stochastic Optimization," arXiv preprint, arXiv:1412.6980, 2014.
<https://arxiv.org/abs/1412.6980>

◎ 저 자 소개 ◎



정 우 진(Woojin Jeong)
2012년 한양대학교 컴퓨터공학과(공학사)
2012년~현재 한양대학교 컴퓨터공학과 박사과정
관심분야 : 컴퓨터비전, 패턴인식, 딥러닝
E-mail : wjjeong@visionlab.or.kr



한 복 규(Bok Gyu Han)
2016년 한림대학교 컴퓨터공학과(공학사)
2016년~현재 한양대학교 컴퓨터공학과 박사과정
관심분야 : 컴퓨터비전, 패턴인식, 딥러닝.
E-mail : bgghan@visionlab.or.kr



이 동 석(Dong Seok Lee)
2008년 인하대학교 컴퓨터정보공학과(공학사)
2008년~현재 한화시스템 영상PGM팀 재직
관심분야 : 영상처리
E-mail : dseok.lee@hanwha.com



최 병 인(Byung In Choi)
2001년 한양대학교 전자공학과(공학사)
2003년 한양대학교 전자전기제어계측공학과(공학석사)
2008년 한양대학교 전자전기제어계측공학과(공학박사)
2006년~현재 한화시스템 영상PGM팀 재직
관심분야 : 영상처리, 탐지추적, 패턴인식
E-Mail : byungin.choi@hanwha.com



문 영 식(Young Shik Moon)
1980년 서울대학교 전자공학과(공학사)
1982년 한국과학기술원 전기 및 전자공학과(공학석사)
1990년 Univ. of California at Irvine, Dept. of Electrical and Computer Engineering(공학박사)
1992년~현재 한양대학교 컴퓨터공학과 교수
관심분야 : 영상처리, 컴퓨터비전, 패턴인식
E-mail : ysmoon@hanyang.ac.kr