

딥러닝 기반 Super Resolution 기술의 현황 및 최신 동향

□ 서유립, 강석주 / 서강대학교

요약

최근 Ultra-High Definition(UHD) 등의 고해상도 디스플레이가 시장에 등장하고 이에 따라 소비자의 요구가 커지면서 기존의 Full-High Definition(FHD)과 같은 저해상도(Low Resolution, LR) 영상을 고해상도(High Resolution, HR) 영상으로 변환할 수 있는 초해상화(Super-Resolution) 알고리즘에 대한 관심이 커지고 있다. 그러나 기존의 전통적인 초해상화 기법들은 고해상도 영상을 복원하는 과정에서 미세한 부분의 화질 저하 및 열화가 존재하는 것을 확인할 수 있다. 본 논문에서는 이러한 문제를 해결하기 위해 최근 널리 연구되고 있는 딥러닝 기반의 초해상화 알고리즘 연구의 최신 기술 현황 및 동향을 소개하고자 한다. 딥러닝 기반의 초해상화 알고리즘은 기존의 전통적인 기법들에 비해 높은 성능을 보여주고 있으며 현재까지도 다양한 네트워크가 제안되며 활발히 연구되고 있다. 본 논문에서는 딥러닝 기반의 초해상화 알고리즘 중 대표적인 네트워크들을 분석하고 다양한 데이터 셋에 대한 해당 네트워크의 실험 결과를 통해 딥러닝 기반의 초해상화 알고리즘의

우수성을 확인하고자 한다.

I. 서론

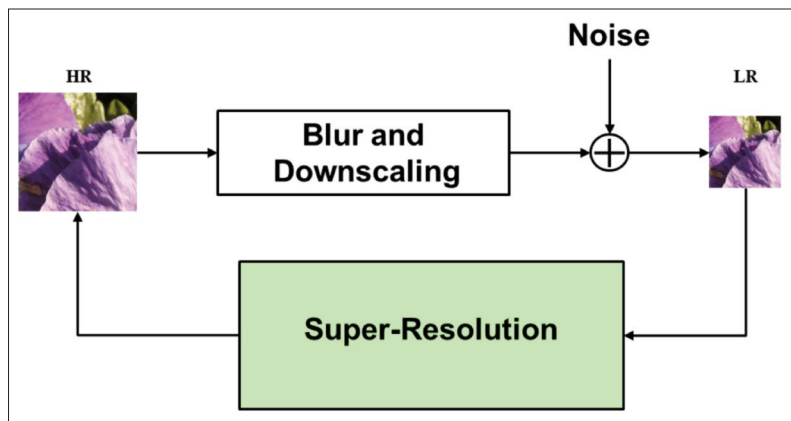
단일 이미지 초해상화는 컴퓨터 비전 연구 분야의 한 갈래로 <그림 1>에서 확인할 수 있듯이 저해상도(Low Resolution, LR) 영상으로부터 고해상도(High Resolution, HR) 영상을 생성하는 기술이다. 일반적으로, 저해상도 영상으로부터 고해상도 영상을 복원하는 문제는 부적절하게 정립된 역 문제(ill-posed inverse problem)로 정의된다. 기존에는 바이큐빅 보간법(Bicubic Interpolation)과 같은 다항식 기반의 보간법 혹은 선형 매핑(Linear Mapping)을 사용하는 로컬 패치(local patch) 기반의 초해상화 기법들이 널리 연구되고 있다. 선형

※ 본 연구는 행정안전부 스마트 도로조명 플랫폼 개발 및 실증 연구 개발사업의 연구비 지원(과제번호 20PQWO-B153358-02)에 의해 수행되었으며, 과학기술정보통신부 및 정보통신기술진흥센터의 대학ICT연구센터지원사업의 연구결과로 수행되었음(IITP-2020-2018-0-01421)

매핑을 사용해 저해상도 패치로부터 바로 고해상도 패치를 복원하는 초해상화 알고리즘은 상대적으로 적은 복잡도와 연산량으로 고품질의 고해상도 영상들을 생성해낼 수 있다. 이 중 저해상도와 고해상도 사전(Dictionary)으로부터 선형 매핑을 학습시켜 고해상도 패치를 생성하는 고정 이웃 회기법(Anchored Neighborhood Regression, ANR)[1] 혹은 같은 저자의 조정된 이웃 회기법(adjusted ANR, A+)[2] 등은 비교적 높은 성능을 보여주었다. 그러나 이러한 기법들은 비교적 단순한 선형 매핑을 기반으로 하기 때문에 복잡하고 비선형적인 저해상도-고해상도 모델을 구현하기 힘들다.

해당 문제를 해결하기 위해 최근 딥러닝(Deep learning) 기반의 초해상화 알고리즘은 가장 일반화된 합성곱 신경망(Convolutional Neural Network, CNN)을 통해 다양한 연구가 진행 중이고 기존 알고리즘 대비 높은 성능을 보여주고 있다. 이는 여러 겹으로 쌓은 다층 네트워크를 사용하여 저해상도 입력과 고해상도 출력 간의 복잡한 비선형적 관계를 정밀하게 분석하여 보다 정확하게 변환할 수 있는 합성곱 필터 파라미터(Filter Parameter)

를 학습한다. Dong은 초해상화 문제에 처음으로 딥러닝을 도입한 네트워크인 Super Resolution Convolutional Neural Network(SRCNN)를 제안하였다[3]. 이는 상대적으로 단순한 3 계층의 Fully Convolution Network(FCN) 구조를 가진 네트워크로서 바이큐빅 보간법으로 확대한 이미지의 화질을 개선하는 알고리즘이다. 해당 네트워크는 기존 초해상화 알고리즘 대비 높은 성능을 보여주며 초해상화 알고리즘에도 딥러닝 기반의 네트워크가 도움이 된다는 사실을 입증하였다. Dong [4]은 이후 네트워크를 보다 경량화하여 연산량과 필터 파라미터수는 감소하면서 성능을 높이는 네트워크인 Fast Super Resolution Convolutional Neural Network(FSRCNN)을 제안하였다. 해당 네트워크는 기존 SRCNN처럼 바이큐빅 보간법으로 해상도가 변환한 이미지의 화질을 개선하지 않고 네트워크내에 이미지를 확대하는 층인 디컨볼루션(Deconvolution) 층을 추가하여 학습을 통해 보다 최적화된 고해상도 이미지를 생성하도록 하였다. 이후 Kim[5]은 20 계층의 상대적으로 깊은 네트워크를 설계하여 보다 깊은 층을 가진 네트워크가 초해상화 알고



<그림 1> 초해상화 알고리즘 문제 정의

리즘에 더 효율적이라는 사실을 보여주었다. 특히 그들은 기존 딥러닝 기반의 물체 구분 알고리즘에 큰 성능을 보인 레즈넷(ResNet)[6]에서 영감을 얻어 잔여 학습(Residual learning) 기술을 통해 보다 깊은 네트워크를 효율적으로 학습시킬 수 있었다. 이후 여러 연구들이 초해상화 알고리즘에 적용되는 다양한 네트워크들을 제안하며 보다 높은 성능을 보여왔고 지금도 많은 연구자들이 딥러닝 기반의 초해상화 알고리즘 관련 연구를 진행하고 있다.

본 논문에서는 위와 같이 딥러닝 기반의 단일 이미지 초해상화 알고리즘을 수행하는 최신 기술 현황 및 동향을 살펴보고자 한다. II장에서는 딥러닝 기반의 네트워크를 이용한 초해상화 알고리즘 기법에 대해 심층적으로 살펴 본 후 III장에서는 다양한 영상에 대한 고해상도 영상 생성 결과를 정량적, 정성적으로 비교 제시하고, 마지막으로 IV장에서 결론을 맺는다.

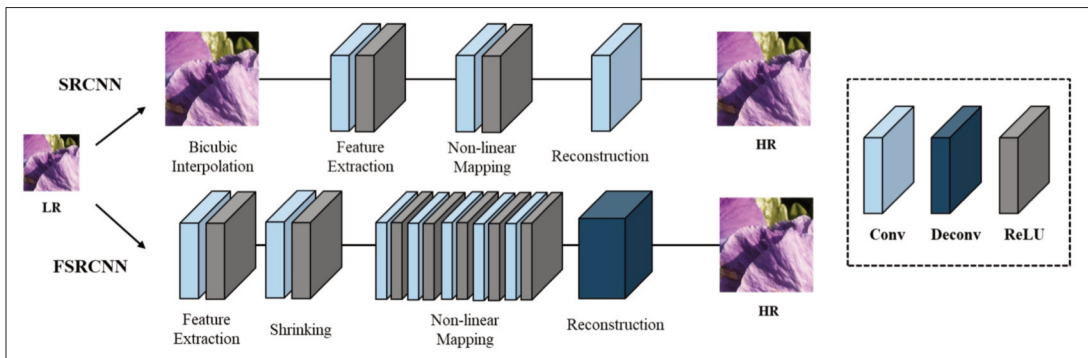
II. 딥러닝 기반의 초해상화 알고리즘 기술 현황 및 동향

이번 장에서는 대표적인 딥러닝 기반의 초해상화

알고리즘 기술들에 대해 자세히 살펴보고자 한다. 먼저 가장 최초로 딥러닝 기반의 합성곱 신경망을 초해상화 알고리즘에 적용한 사례인 SRCNN과 FSRCNN에 대해 알아보겠다. 이후 잔여 학습을 통해 깊은 네트워크를 효율적으로 학습이 가능하게 하도록 한 Very Deep Super Resolution(VDSR)과 최근 이전의 네트워크 대비 가장 높은 성능을 보여주고 있는 Enhanced Deep Super Resolution(EDSR)[7]에 대해 알아보겠다. 다음으로 딥러닝을 학습하는 또 다른 방법인 비지도학습의 대표주자인 생성적 적대 신경망(Generative Adversarial Network, GAN)을 초해상화 알고리즘에 처음으로 적용한 Super Resolution Generative Adversarial Network(SRGAN)[8]에 대해 알아보도록 하겠다.

1. 합성곱 신경망을 사용한 초해상화 네트워크 설계

Dong은 초해상화 분야에 최초로 딥러닝 기반의 CNN을 적용한 연구인 SRCNN을 제안했다. 이전의 초해상화 연구는 각각의 단계를 처리하는 여러 알고리즘들을 종합적으로 합쳐서 초해상화를 수행하였다



<그림 2> SRCNN/FSRCNN 네트워크 구조

면, SRCNN은 최초로 end-to-end 방식으로 모든 단계를 하나의 통합된 네트워크에서 처리하였다. 입력 LR 영상으로는 바이큐빅 보간법을 적용해 업스케일링 된 이미지를 사용한다. 즉, CNN 네트워크를 통과하면서 영상의 해상도에는 변화가 없다. 해당 연구는 매우 단순한 방법으로 기존의 신호처리 관점에서 바라보았던 초해상화 문제를 딥러닝의 관점에서 풀어내면서 높은 성능을 보여준데에 그 의의가 있다.


SRCNN의 구조는 <그림 2>와 같다. 상대적으로 단순한 3 계층의 FCN 구조를 가지고 있고 최근 제안되는 네트워크와 다르게 전통적인 초해상화 기법의 관점에서 각각의 층의 역할을 분석하였다. 첫 번째 층은 패치 추출(Patch Extraction) 역할로 LR 영상에서 패치들을 추출하여 feature map 단위로 표현하는 단계이다. 두 번째 층에서는 각각의 feature map을 또 다른 feature map으로 매핑하는 역할을 한다. 이때 매핑은 비선형적으로 이루어진다. 마지막 층에서는 비선형적으로 매핑된 feature map들을 바탕으로 HR 영상을 생성해낸다.

이후 Dong은 후속 논문에서 보다 최적화된 네트워크인 FSRCNN을 제안하였다. 기존 SRCNN 대비 FSRCNN의 가장 큰 차이점은 입력으로 들어가는 LR 영상을 바이큐빅 보간법을 사용하여 업스케일링 하지 않고 그대로 네트워크에 넣는 방식을 사용한 것이다. 기존 SRCNN에서 입력 LR 영상의 해상도를 출력 HR 영상의 해상도로 업스케일링 시킨 뒤 CNN 연산을 하는 과정이 매우 비효율적임을 지적하면서 해당 네트워크에서는 영상의 해상도를 변화하기 위해서 디컨볼루션(Deconvolution) 층을 사용하였다. 디컨볼루션 연산은 feature map의 가로 세로 크기를 키워주는 역할을 하기 때문에 원하는 해상도로 출력 영상을 늘릴 수 있다. 이렇게 낮은 해상도의 입력 LR 이미지를 사용한다면 업스케일

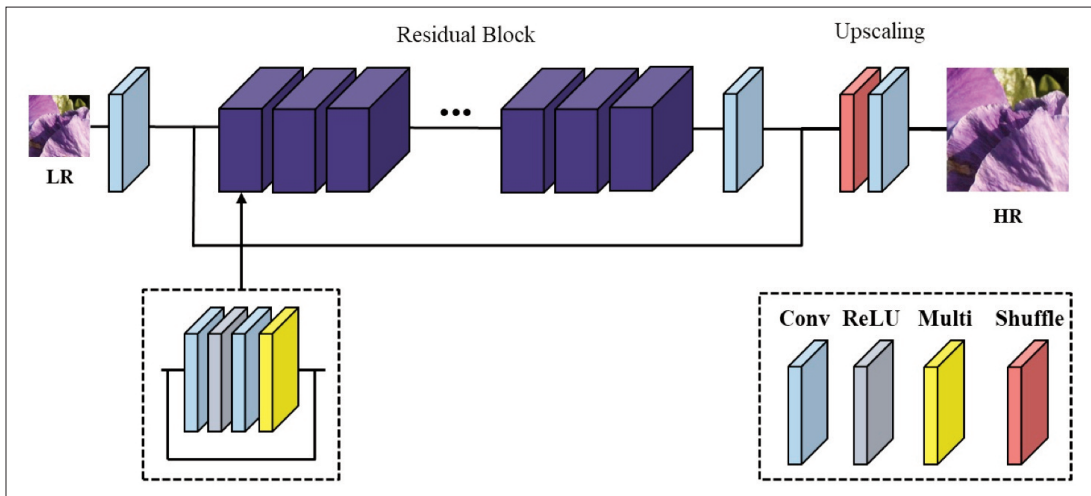
링 하고자 하는 배수의 제공에 비례하여 연산량이 줄어들게 된다. 결과적으로 FSRCNN은 SRCNN 대비 낮은 파라미터 수와 높은 연산속도를 보여주고 성능도 더 높은 장점이 있다.

2. 잔여 학습을 통한 깊은 초해상화 네트워크 설계

일반적으로 깊은 딥러닝 모델로 깊은 네트워크를 설계한다면 연산량이 많아지고 파라미터 수가 증가한다. 그러나 깊은 네트워크를 학습 시 역전파(Backpropagation) 과정에서 입력층으로 갈수록 기울기(Gradient)가 점차적으로 작아지는 현상인 기울기 소실(Gradient Vanishing) 문제가 발생하거나 기울기가 비정상적으로 커지는 기울기 폭발(Gradient Exploding) 문제가 발생해 필터 파라미터들이 제대로 학습이 되지 않는 문제가 발생할 수 있다. 따라서 단순히 네트워크만 깊게 설계한다고 해서 네트워크의 성능이 그에 비례하게 증가하지 않는다. 이러한 문제를 해결하기 위해 Kaiming He는 잔여 학습이라는 새로운 학습방법을 제시해 깊은 네트워크에서도 위의 문제가 발생하지 않고 성능을 높일 수 있는 레즈넷을 제안하였다. 잔여 학습이란 입력 LR 영상을 최종 출력 HR 영상에 더해주고 두 영상의 차이 값을 학습하는 방법이다. 일반적으로 입력 LR 영상과 출력 HR 영상은 비슷하기 때문에 그 차이 값은 매우 작거나 0이므로 기울기 소실/폭주 문제를 해결할 수 있었다. <그림 3>에서 확인할 수 있듯이 Kim은 이 잔여 학습을 이용하여 이 논문이 발표된 시기에 상대적으로 깊은 20층의 네트워크를 가지는 VDSR을 제안하였다. VDSR은 SRCNN과 마찬가지로 바이큐빅 보간법으로 업스케일링 된 입력 LR 영상과 출력 HR 영상을 네트워



<그림 3> VDSR 네트워크 구조



<그림 4> EDSR 네트워크 구조

크 학습 시 사용한다. 그러나 SRCNN과 다르게 입력 LR 영상과 출력 HR 영상의 차이를 네트워크에 입력하여 마지막 출력단에서 입력 LR 영상을 더해 준다. 이렇게 학습을 진행한다면 단순히 덧셈이 추가되는 형태로 연산을 단순화할 수 있고 깊은 네트워크에서도 쉽게 최적화가 가능하다.

이 후 여러 네트워크들이 이 잔여 학습을 이용해 보다 깊은 네트워크를 설계하였다. 그 중 Lim은 매우 깊고 넓은 네트워크인 EDSR을 제안해 높은 성능을 보였다. EDSR은 32개 이상의 층을 사용하였고 채널 수도 기존의 다른 네트워크 대비 4배 이상 늘려 파라미터 수도 그에 비례하여 매우 많이 증가

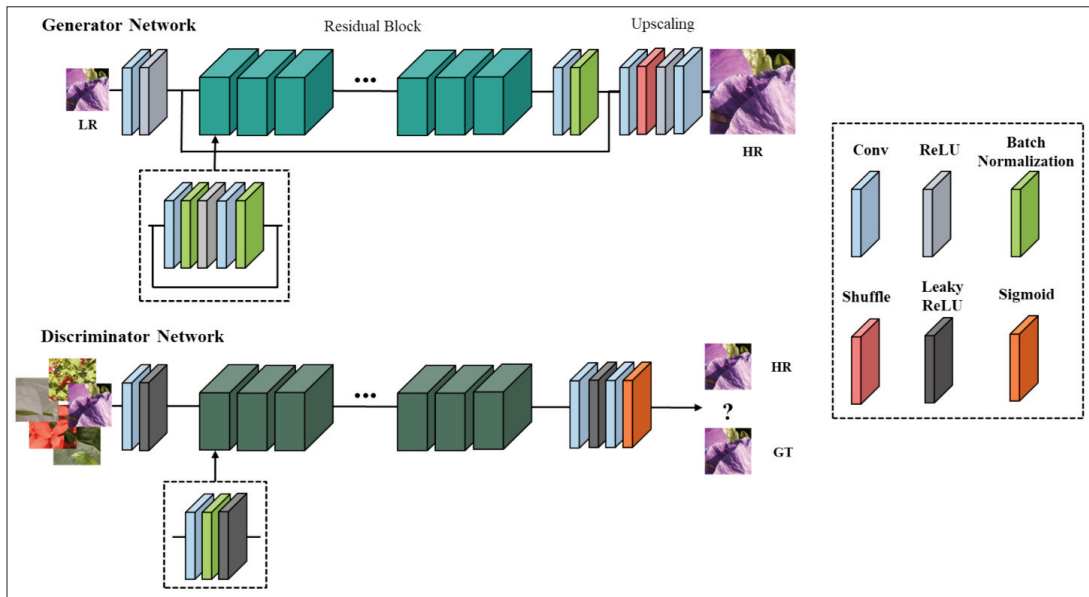
하였다. <그림 4>에서 확인할 수 있듯이 저자는 깊은 네트워크를 보다 안정적으로 학습하기 위해 네트워크를 잔여 블록(Residual Block) 별로 나누고 각각을 스킵 커넥션(Skip Connection)을 사용해 연결하며 필터 파라미터들이 더 쉽게 최적화되도록 네트워크를 설계하였다. 또한 각각의 잔여 블록 안에서 feature map들이 더해지면서 feature map들의 분산이 커지는 경우가 생겨 학습이 잘 안되는 문제를 해결하기 위해 일정한 상수 값을 CNN 층 이후에 곱해주는 Multi 층을 추가하였다. EDSR에서는 SPCNN(Sub Pixel Convolutional Neural Network)[9]을 사용해 학습과정에서 입력 LR 영상

의 해상도를 키웠다. SPCNN을 사용한다면 CNN 층을 거친 뒤 마지막 층에서 feature map의 개수를 업스케일링 배수의 제곱 개만큼 늘려준 뒤 이를 픽셀 셔플(Pixel Shuffle) 연산을 통하여 적절히 배치하여 원하는 해상도의 출력 HR 영상을 복원해낼 수 있다. 이는 기존 바이큐빅 보간법을 사용해 입력 LR 영상의 해상도를 키우고 네트워크에 입력한 VDSR 대비 효율적인 연산이 가능하고 네트워크 정확도 또한 높아졌다. 결과적으로 EDSR은 동 년도에 제안된 다른 딥러닝 기반의 초해상화 네트워크 대비 높은 성능을 보여줬으며 이 후 제안된 다양한 초해상화 네트워크에 많은 영향을 주었다.

3. 생성적 적대 신경망을 통한 초해상화 네트워크 설계

일반적으로 딥러닝 기반의 초해상화 네트워크를

학습시킬 때는 입력 LR 영상을 네트워크에 입력하여 복원된 출력 HR 영상과 Ground Truth(GT) 영상 간의 MSE(Mean Square Error) loss 함수를 사용하여 학습을 진행한다. 따라서 복원된 출력 HR 영상의 PSNR(Peak Signal-to Noise Ratio) 수치는 높게 학습이 되지만 인지적으로 선명한 영상을 얻기는 어려울 수도 있다. Ledig는 이러한 문제를 해결하기 위해 기존의 지도 학습 기반의 딥러닝 네트워크가 아닌 비지도 학습 기반의 GAN을 사용하여 초해상화 문제를 해결하려는 시도를 하였다. 저자가 제안한 SRGAN 네트워크의 구조는 <그림 5>와 같다. SRGAN 네트워크는 이미지를 복원하는 생성(Generator) 네트워크와 학습 시 GT 영상과 출력 HR 영상을 비교하여 구분하는 분류(Discriminator) 네트워크로 구성되어 있다. 또한 학습 시 기존 MSE loss 대신 기존의 딥러닝 기반의 영상 분류 네트워크 중 하나인 VGG 네트워크[10]를 사용하



<그림 5> SRGAN 네트워크 구조

는 Perceptual loss를 통해 인지적으로 보다 뛰어난 영상을 얻을 수 있도록 학습할 수 있었다. Perceptual loss란 [11]에서 처음으로 제안된 손실 함수로 입력과 GT를 미리 학습해 놓은 다른 딥러닝 기반의 영상 분류 네트워크에 통과 시킨 후 얻은 feature map 사이의 손실을 최소화 하는 방향으로 필터 파라미터를 학습한다. 생성 네트워크에서는 학습을 통해 출력 HR 영상을 복원해내고 분류 네트워크는 해당 생성 이미지를 GT와 비교하여 최대한 정확도가 높은 방향으로 전체 GAN 네트워크를 학습시키게 된다. SRGAN은 기존의 다른 딥러닝 기반의 초해상화 알고리즘 대비 PSNR 수치는 낮지만 인지적으로 뛰어난 영상을 복원하였고 높은 업스케일링 배수에 보다 더 잘 적용됨을 보였다.

또한 저자는 일반적인 SRGAN과 동일한 네트워크 구조를 가지지만 기존의 딥러닝 기반의 초해상화 알고리즘과 동일하게 MSE loss 함수를 사용해 학습한 네트워크인 SRResNet을 제안하였다. 해당 네트워크 출력 HR 영상은 PSNR 수치는 SRGAN 보다 높게 나오지만 디테일한 이미지의 영역에서

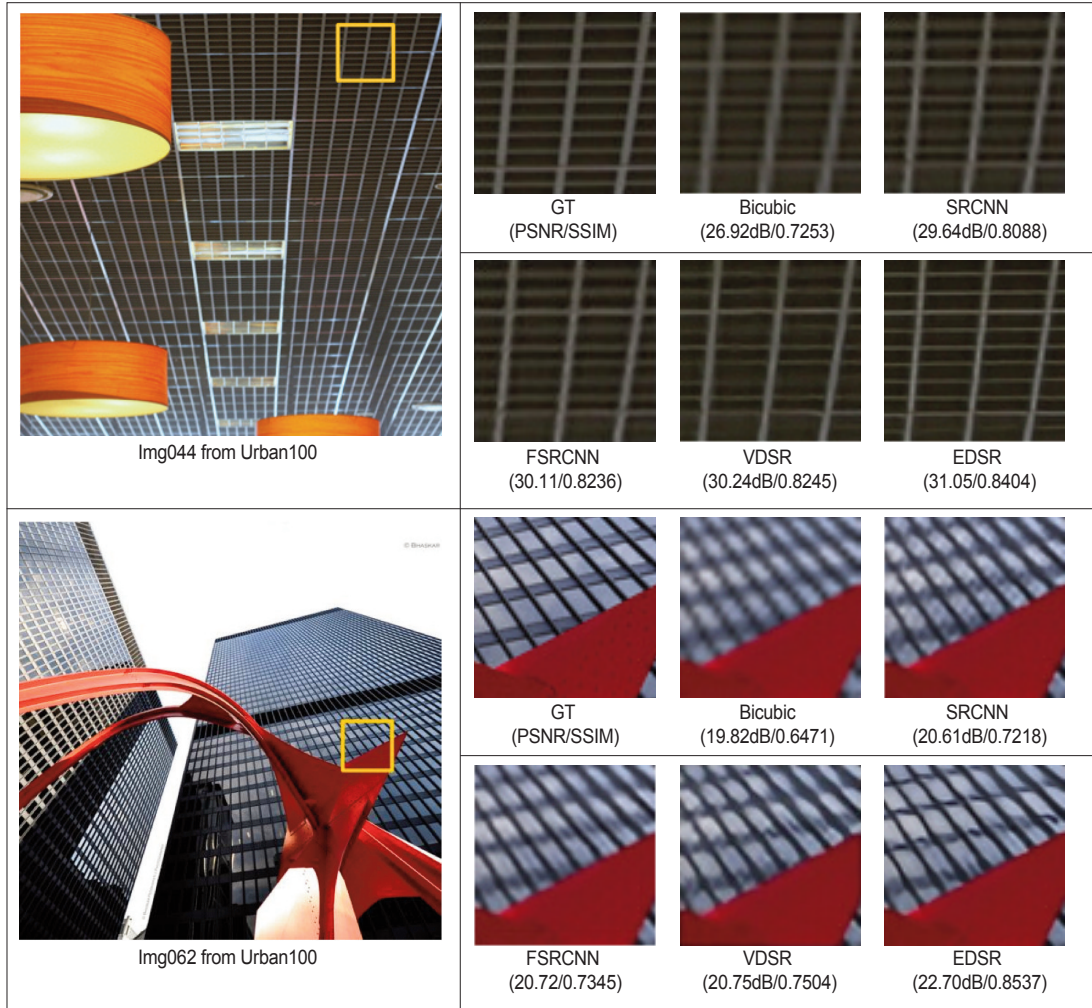
SRGAN의 출력 HR 영상이 보다 인지적으로 선명하게 보이는 것을 확인할 수 있다.

III. 네트워크 결과 성능 비교

이번 장에서는 딥러닝 기반 초해상화 알고리즘을 평가할 때 널리 쓰이는 데이터셋인 Set5[12], Set14[13], BSDS100[14], Urban100[15]에 대한 출력 HR 영상의 결과를 살펴보고자 한다. 정량적 평가 방법으로는 영상의 화질을 평가하는 대표적인 평가 매트릭인 PSNR과 SSIM(Structural SIMilarity)을 사용하였다. <표 1>에서 확인할 수 있듯이 모든 업스케일링 배수 2, 3, 4에 대하여 SRCNN과 같은 딥러닝 기반의 초해상화 네트워크는 바이큐빅 보간법, A+ 대비 높은 성능을 보여주는 것을 확인할 수 있고 EDSR은 그 중 가장 높은 성능을 보여주었다. <그림 6>에서는 업스케일링 배수 4에 대한 다양한 네트워크의 출력 HR 영상을 통해 각각 네트워크의 성능을 확인할 수 있다. <그림 6>에서 확인할 수 있듯이 비교적 높

<표 1> 출력 HR 영상의 정량적 수치 평가

Dataset	Scale	Bicubic	A+	SRCNN	FSRCNN	VDSR	EDSR
Set5	2	33.66/0.9299	36.55/0.9544	36.66/0.9542	37.00/0.9558	37.53/0.9587	38.110.9601
	3	30.39/0.8682	32.59/0.9088	32.75/0.9090	33.16/0.91440	33.66/0.9213	34.65/0.9282
	4	28.42/0.8104	30.28/0.8603	30.48/0.8628	30.71/0.8657	31.35/0.8838	32.46/0.8968
Set14	2	30.24/0.8688	32.28/0.9056	32.42/0.9063	32.63/0.9088	33.03/0.9124	34.92/0.9195
	3	27.55/0.7742	29.13/0.8188	29.28/0.8209	29.43/0.8242	29.77/0.8314	30.52/0.8462
	4	26.00/0.7027	27.33/0.7491	27.49/0.7503	27.59/0.7535	28.01/0.7674	28.80/0.7876
BSDS100	2	29.56/0.8431	30.78/0.8861	31.36/0.8879	31.80/0.9074	31.90/0.8960	32.32/0.9013
	3	27.21/0.7385	28.18/0.7835	28.41/0.7836	28.60/0.8137	28.82/0.7976	29.25/0.8093
	4	25.96/0.6675	26.77/0.7087	26.90/0.7101	26.98/0.7398	27.29/0.7251	27.71/0.7420
Urban100	2	26.88/0.8403	29.25/0.8938	29.50/0.8946	-	30.76/0.9140	32.93/0.9351
	3	24.46/0.7349	26.05/0.7973	26.24/0.7989	-	27.14/0.8279	28.80/0.8653
	4	23.14/0.6577	24.34/0.7183	24.52/0.7221	-	25.18/0.7524	26.64/0.8033



<그림 6> 초해상화 알고리즘 출력 HR 영상 결과 (업스케일링 배수 4)

은 업스케일링 배수 4에 대하여 바이큐빅 보간법은 GT 영상을 제대로 복원해내지 못하고 blur 한 것을 확인할 수 있다. 이에 반해 SRCNN 같은 딥러닝 기반의 초해상화 네트워크의 경우 비교적 선명하게 출력 HR 영상을 복원해낸다. 또한 더 깊어진 네트워크인 VDSR 혹은 EDSR과 같은 경우 보다 더 영상의 디테일을 잘 복원해내는 것을 확인할 수 있다.

IV. 결론

본 논문에서는 인공지능 기술, 특히, 심층학습을 이용한 초해상화 알고리즘 기술 현황 및 동향에 대해 살펴보았다. 고해상도 디스플레이 시장이 커지고 그에 따라 기존의 영상 콘텐츠의 해상도를 늘리는 초해상화 기술의 필요성이 꾸준히 제기되고 있지만 아직 기존의 초해상화 기법으로 획득되는 영

상에는 여전히 화질이 저하되는 문제가 발생한다. 컴퓨터 비전 분야에서는 이를 해결하기 위해 딥러닝 기반의 네트워크를 이용하여 초해상화 문제를 해결하려는 방법에 대해 활발히 연구가 진행되고 있다. 딥러닝 기반의 초해상화 알고리즘은 대용량 학습을 통해 효과적으로 영상 화질을 개선할 수 있기 때문에 최근 기존의 알고리즘 대비 높은 성능을 보여주고 있다. 그러나 딥러닝 기반의 알고리즘은

높은 연산량을 가지고 있고 많은 파라미터 수를 요구하기 때문에 실제 디스플레이에 해당 알고리즘을 구현하기 위해서는 모델 압축 및 최적화와 같은 추가적인 연구가 요구된다. 이를 효과적으로 해결한다면 보다 선명한 영상을 보여주는 딥러닝 기반의 초해상화 알고리즘이 성공적으로 고해상도 디스플레이 시스템에 적용될 수 있을 것으로 기대된다.

참고 문헌

- [1] R. Timofte, V. De, and L. Van Gool. "Anchored neighborhood regression for fast example-based super-resolution." IEEE International Conference on Computer Vision (ICCV), pp. 1920-1927, 2013.
- [2] R. Timofte, V. De Smet, and L. Van Gool. "A+: Adjusted anchored neighborhood regression for fast super-resolution." Asian Conference on Computer Vision (ACCV), pp. 111-126. Springer, 2014.
- [3] C. Dong, C.C. Loy, K. He, and X. Tang, "Image super-resolution using deep convolutional networks." European Conference on Computer Vision (ECCV), Springer, pp. 184-199, 2014.
- [4] Dong, Chao, Chen Change Loy, and Xiaoou Tang. "Accelerating the super-resolution convolutional neural network." European conference on computer vision. Springer, Cham, 2016.
- [5] J. Kim, J.K. Lee, and K.M. Lee. "Accurate image super-resolution using very deep convolutional networks." IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1637-1645, 2016.
- [6] K. Simonyan, A. Zisserman. "Very deep convolutional networks for large-scale image recognition." International Conference on Learning Representations (ICLR), pp. 1-14, 2015.
- [7] B. Lim, S. Son, H. Kim, S. Nah, and K.M. Lee, "Enhanced deep residual networks for single image super-resolution." IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1132-1140, 2017.
- [8] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Aitken, A. Tejani, J. Totz, Z. Wang, and W. Shi. Photo-realistic single image super-resolution using a generative adversarial network. arXiv preprint arXiv:1609.04802, 2016.
- [9] W. Shi, J. Caballero, F. Huszar, J. Totz, A. P. Aitken, R. Bishop, D. Rueckert, and Z. Wang. "Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network." IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1874-1883, 2016.
- [10] K. Simonyan and A. Zisserman. Very deep convolutional networks for large-scale image recognition. In International Conference on Learning Representations (ICLR), 2015
- [11] J. Johnson, A. Alahi, and L. Fei-Fei. Perceptual losses for real-time style transfer and super-resolution. European Conference on Computer Vision (ECCV), pp 694-711. Springer, 2016
- [12] M. Bevilacqua, A. Roumy, C. Guillemot, and M. L. Alberi-Morel. "Low-complexity single-image super-resolution based on nonnegative neighbor embedding." British Machine Vision Conference (BMVC), pp. 1-10, 2012.
- [13] R. Zeyde, M. Elad, and M. Protter, "On single image scale-up using sparse-representation," International Conference on Curves and Surfaces, Springer, pp. 711-730, 2010.
- [14] D. Martin, C. Fowlkes, D. Tal, and J. Malik, "A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics." Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on. IEEE, vol. 2, pp. 416-423, 2001.
- [15] J. B. Huang, A. Singh, and N. Ahuja. "Single image super-resolution from transformed self-exemplars." IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 5197-5206, 2015.

필자소개



서유림

- 2019년 2월 : 서강대학교 전자공학과 학사
- 2019년 3월 ~ 현재 : 서강대학교 전자공학과 석사
- 주관심분야 : 컴퓨터 비전, 딥러닝 기반 영상 신호 처리, 초고해상도 복원



강석주

- 2011년 ~ 2012년 : LG디스플레이 회로 및 알고리즘 선임연구원
(무안경 3차원 디스플레이 및 UHD 해상도 향상 시스템 Project Leader)
- 2012년 ~ 2015년 : 동아대학교 전기공학과 조교수
- 2015년 ~ 현재 : 서강대학교 전자공학과 부교수
- 주관심분야 : 디스플레이 시스템 및 회로 설계, 영상 및 비디오 신호 처리, 딥러닝 기반 영상 신호 처리