

## 다층 선형 매핑 기반 단일영상 초해상화 기법

최재석, 김문철

한국과학기술원 전기 및 전자 공학부

jschoi14@kaist.ac.kr, mkimee@kaist.ac.kr

### Single Image Super-Resolution Using Multi-Layer Linear Mappings

Jae-Seok Choi, Munchurl Kim

Korea Advanced Institute of Science and Technology

#### 요 약

최근 UHDTV(ultra high definition television) 등의 고해상도 디스플레이가 시장에 등장하면서, 기존의 저해상도 FHD(full high definition) 영상을 고해상도 영상으로 변환할 수 있는 초해상화(super-resolution, SR) 기법들이 각광을 받고 있다. 그 중, 선형 매핑(linear mapping)을 사용하여 저해상도 패치(patch)로부터 고해상도 패치를 복원하는 초해상화 기법은 상대적으로 낮은 복잡도로 좋은 품질의 고해상도 영상을 생성한다. 그러나 이러한 기법은 단순한 선형 매핑을 기반으로 하기 때문에 복잡한 비선형적(nonlinear) 저해상도-고해상도 관계를 예측하기 힘든 단점이 있다. 최근 각광받는 딥러닝(deep learning) 기술은 다층(multi-layer) 네트워크를 쌓아 입력과 출력 간의 복잡한 비선형 관계를 훈련시켜 좋은 성능을 보이는데, 이를 바탕으로 본 논문에서는 다중의 레이어로 구성된 다층 선형 매핑(multi-layer linear mappings, MLLM)을 기반으로 하는 초해상화 기법을 새롭게 제안한다. 제안하는 다층 선형 매핑은 기존 선형 매핑보다 비선형적 관계를 더 잘 예측하여 높은 품질의 고해상도 영상을 생성할 수 있게 한다. 제안된 초해상화 기법은 딥러닝 기반 초해상화 기법과 필적하는 품질의 고해상도 영상을 생성하면서도 더 낮은 복잡도를 지니는 것을 확인하였다.

#### 1. 서론

UHDTV(ultra high definition television)의 등장으로 기존 저해상도 FHD(full high definition) 영상을 재할용하여 고해상도 UHD 영상으로 변환할 수 있는 초해상화(super-resolution, SR) 기법의 필요성이 대두되고 있다. 이 초해상화 기법은 저해상도(low-resolution, LR) 영상에서 주관적/객관적으로 더 좋은 품질의 고해상도(high-resolution, HR) 영상을 생성하는 기술이다. 일반적으로, 저해상도 입력 영상에서 원래의 고해상도 영상을 복원하는 문제는 부적절하게 정립된 역 문제(ill-posed inverse problem)로 정의된다[1]. 즉 어떤 특정 저해상도 영상을 생성할 수 있는 원래의 고해상도 영상들은 무한히 존재하고, 이 중에서 정답인 고해상도 원본 영상을 알아내기가 매우 힘들다. 초해상화 기법은 추가적인 사전 지식(prior)를 활용하여 정답 자체보다는 정답에 근접한 고해상도 영상을 복원하는 것에 목적이 있다. 한 예시로, 특정 저해상도 패치와 이에 해당되는 고해상도 패치는 동일한 희소(sparse) 가중치를 공유한다라는 사전 지식을 사용하는 희소 부호화 기반 초해상화(sparse coding super-resolution, SCSR) 기법[2]이 있다.

다양한 초해상화 기법들 중, 선형 매핑(linear mapping)을 사용하여 저해상도 패치(patch)로부터 바로 고해상도 패치를 복원하는 초해상화 기법들[3-7]은 상대적으로 적은 복잡도로 고품질의 고해상도 영상들을 생성할 수 있다. SCSR 기법에서 사용된 저해상도-고해상도 사전(dictionary)들로부터 새로이 선형 매핑들을 훈련시켜 고해상도 패치 생성에 활용하는 고정 이웃 회귀법(anchored neighborhood regression, ANR)[3]과

같은 저자의 조정된 고정 이웃 회귀법(adjusted ANR, A+)[4] 등이 제안되었다. 이러한 초해상화 기법들은 단순한 선형 매핑을 기반으로 하기 때문에 복잡한 비선형적(nonlinear) 저해상도-고해상도 관계 모델(model)을 예측하기가 힘들다.

최근 각광받는 딥러닝(deep learning) 기술[8]은 여러 겹으로 쌓은 다층(multi-layer) 네트워크를 사용하여 입력과 출력 간의 복잡한 비선형 관계를 정밀하게 예측할 수 있는 것으로 알려져 있다. 이로부터 착안하여, 본 논문에서는 다중의 레이어로 구성된 다층 선형 매핑(multi-layer linear mappings, MLLM) 기반 초해상화 기법을 새로이 제안한다.

제안하는 MLLM 초해상화 기법은 기존 초해상화 기법들[3-7]의 단일 선형 매핑 기반 고해상도 패치 생성 방법의 한계를 보완하고, 복잡한 비선형적 저해상도-고해상도 관계를 더 잘 예측하여 높은 품질의 고해상도 영상을 생성할 수 있게 한다. 실험을 통해 본 초해상화 기법이 딥러닝 기반 초해상화 기법[8]과 더 좋거나 필적하는 품질의 고해상도 영상을 생성하면서도 더 낮은 복잡도를 지니는 것을 확인하였다.

#### 2. 제안하는 MLLM 기반 초해상화 기법

본 기법은 다량의 훈련 영상들을 사용하여 다층 선형 매핑들을 미리 훈련시키는 훈련(training) 단계와, 실제로 저해상도 영상이 입력되었을 때 이를 고해상도 영상으로 복원하는 실험(testing) 단계로 이루어진다.

본 제안 방법은 총 세 개의 층으로 이루어져 있는데, 첫 번

째 층에서는 각 저해상도 입력 패치가 훈련 단계에서 미리 훈련시킨 군집화 선형 매핑(cluster-wise linear mapping)을 통해 고해상도 패치로 변환되고, 모든 생성된 고해상도 패치가 모여 첫 번째 층의 중간 영상으로 저장된다. 여기서 사용되는 군집화 선형 매핑 기법은 저해상도 패치들의 방향성을 분석하여 K개의 그룹으로 나누고, 각 그룹의 저해상도 패치를 해당 고해상도 패치로 매핑하는 선형 매핑을 훈련 단계에서 훈련 및 저장하고, 실행 단계에서 바로 사용하는 기법이다. 훈련 단계에서는 각 그룹 k의 벡터화된 저해상도 훈련 패치들  $\mathbf{Y}_k$  과 벡터화된 고해상도 훈련 패치들  $\mathbf{X}_k$  간의 선형 매핑  $\mathbf{M}_k$  를 아래 식과 같이 다변량 회귀 방법(multivariate regression) [9]을 사용하여 훈련시킨다.

$$\mathbf{M}_k = \mathbf{X}_k \mathbf{Y}_k^T (\mathbf{Y}_k \mathbf{Y}_k^T + \lambda \mathbf{I})^{-1} \quad (1)$$

실행 단계에서는 각 저해상도 입력 패치  $\mathbf{y}_i$  의 방향성을 분석하고 해당하는 k번째의 선형 매핑  $\mathbf{M}_k$  을 다음 식처럼 적용시켜 고해상도 패치  $\mathbf{x}_i$  를 생성한다.

$$\mathbf{x}_i = \mathbf{M}_k \mathbf{y}_i \quad (2)$$

이때, 초보간법(super-interpolation, SI) [5]의 효율적인 축소화 패치 변환 기법을 바탕으로 저해상도 패치가 고해상도 패치로 변환된다. 이중 큐빅 보간법(bicubic interpolation)을 사용하여 저해상도 입력 영상을 보간된 중간 영상으로 변환 후 초해상화를 실행하는 기존 초해상화 기법들과는 달리, 본 제안 방법은 작은 저해상도 입력 영상을 바로 고해상도 영상으로 변환시키기 때문에 총 처리해야 하는 패치 수가 줄어들어 계산 시간이 단축된다. 입력 영상을 2배로 키울 시, 첫 번째 층에서의 저해상도 패치 크기는  $3 \times 3$ 로, 고해상도 패치 크기는  $2 \times 2$ 로 설정되며, 선형 매핑의 크기는  $9 \times 4$ 가 된다.

마찬가지로, 두 번째 층에서는 첫 번째 층에서 생성된 중간 영상을 입력으로, 정답 고해상도 영상을 출력으로 두고, 이 둘 사이의 새로운 군집화 선형 매핑들을 훈련시킨다. 첫 번째 층과 다르게 두 번째 층에서는 입력 영상이 커진 상태이므로, 입력 패치 크기는  $6 \times 6$ 으로, 고해상도 패치는 전과 같게  $2 \times 2$ 로 설정되며, 선형 매핑의 크기는  $36 \times 4$ 가 된다. 세 번째 층에서도 동일하게 새 군집화 선형 매핑들을 훈련시키며, 훈련 단계가 끝나면 총  $3 \times K$ 개의 군집화 선형 매핑들이 저장된다. 여기서 더 많은 층을 사용해도 성능의 향상이 미미하기 때문에 세 개의 층까지만 훈련시킨다.

이러한 다층의 선형 매핑들은 기존 선형 매핑들보다 복잡한 저해상도-고해상도 비선형성을 보다 잘 예측할 수 있게 된다.

### 3. 실험 결과

본 제안 방법의 비교 실험을 위하여 이중 큐빅 보간법, ANR 기법 [3], 딥러닝 기반 초해상화 기법(SRCNN15) [8]과 제안하는 MLLM 초해상화 기법이 사용되었다. 다음 표 1은 실험 영상들에 대한 PSNR과 구조 유사도 척도(SSIM) [10]을 나타낸다.

제안하는 MLLM 초해상화 기법은 간단한 선형 매핑을 사용하는 ANR 기법 [3]보다 더 높은 품질의 고해상도 영상을 복원하며, 최신 딥러닝 기반 SRCNN15 기법 [8]과 필적하는 품질의 영상을 생성한다. 이는 MLLM의 다층 선형 매핑들은 기존

단순 선형 매핑들보다 고해상도 복원 능력이 더 뛰어나면서도, 딥러닝처럼 저해상도-고해상도 비선형 모델을 더 잘 예측할 수 있음을 보여주고 있다. 또한, GPU를 사용하여 일주일 정도의 훈련 시간이 걸리는 SRCNN15 기법 [8]과는 달리, 본 제안 방법은 CPU를 사용하여 1시간 이내의 훈련 시간을 지니고 있으며, 실제 저해상도 입력 영상에 초해상화를 적용할 때 걸리는 실행 시간 또한 제안하는 MLLM 기법이 SRCNN15 기법보다 더 적은 것을 알 수 있다.

표 1. 객관적 품질 비교표.

영상 종류		이중 큐빅	ANR [3]	SRCNN15 [8]	제안 방법
bird	PSNR	36.74	39.91	40.61	<b>40.79</b>
	SSIM	0.9726	0.9849	0.9863	<b>0.9865</b>
	시간	0.01	0.76	4.16	0.91
butterfly	PSNR	27.46	30.48	32.59	<b>32.84</b>
	SSIM	0.9155	0.9516	0.9650	<b>0.9681</b>
	시간	0.01	0.61	3.49	0.75
head	PSNR	34.89	35.69	35.75	<b>35.79</b>
	SSIM	0.8631	0.8844	0.8866	<b>0.8870</b>
	시간	0.01	0.72	3.83	0.83

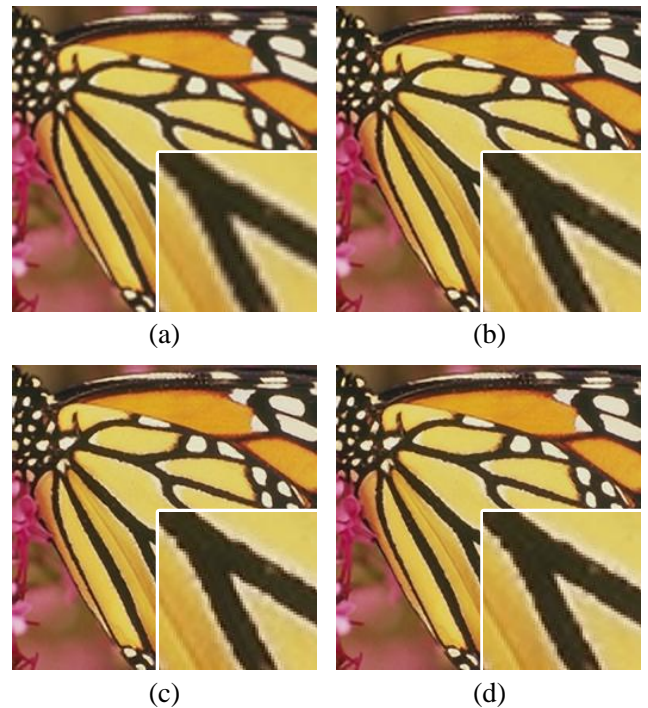


그림 1. 복원된 butterfly 고해상도 영상들의 주관적 품질 비교. (a) 이중 큐빅 보간법, (b) ANR [3], (c) SRCNN15 [8], (d) 제안 방법.

그림 1은 주관적 화질을 비교하기 위해 비교 기법들과 제안하는 기법을 사용하여 복원한 고해상도 영상들을 보이고 있다. 여기서 본 제안 방법이 이중 큐빅 보간법과 ANR 기법보다 높은 주관적 품질의 고해상도 영상을 생성하는 것을 확인할 수 있다. 또한, 제안하는 MLLM 초해상화 기법은 SRCNN15 기법보다 더 적은 복잡도를 지니면서도 SRCNN15가 복원한 고해상도 영상과 유사한 화질의 영상을 생성한다.

## 4. 결론

본 논문에서는 다중의 레이어로 쌓은 다층 선형 매핑을 사용하는 새로운 초해상화 기법을 제안하였다. 실험 결과, 제안하는 MLLM의 다층 선형 매핑은 기존 단순 선형 매핑보다 복잡한 비선형적 저해상도-고해상도 관계를 더 잘 예측하고, 더 낮은 복잡도로 딥러닝 기반 기법으로 복원된 영상의 화질과 필적하는 화질의 고해상도 영상을 생성하는 것을 확인할 수 있었다.

visibility to structural similarity,” IEEE Trans. Image Process., vol. 13, no. 4, pp. 600–612, Apr. 2004.

## 감사의 글

본 논문 연구는 연구재단 중견연구자사업 핵심연구(개인) 과제(과제번호: 2014R1A2A2A01006642)로 수행되었습니다.

## 참고문헌

- [1] K. I. Kim and Y. Kwon, “Single-image super-resolution using sparse regression and natural image prior,” IEEE Trans. Pattern Anal. Mach. Intell., vol. 32, no. 6, pp. 1127–1133, Jun. 2010.
- [2] J. Yang, J. Wright, T. S. Huang, and Y. Ma, “Image super-resolution via sparse representation,” IEEE Trans. Image Process., vol. 19, no. 11, pp. 2861–2873, Nov. 2010.
- [3] R. Timofte, V. De and L. Van Gool, “Anchored neighborhood regression for fast example-based super-resolution,” IEEE Int. Conf. Comp. Vis., Sydney, Australia, Dec. 2013, pp. 1920–1927.
- [4] R. Timofte, V. De and L. Van Gool, “A+: adjusted anchored neighborhood regression for fast super-resolution,” Asian Conf. Comp. Vis., Singapore, Singapore, Nov. 2014, pp. 111–126.
- [5] J.-S. Choi and M. Kim, “Super-interpolation with edge-orientation-based mapping kernels for low complex 2x upscaling,” IEEE Trans. Image Process., vol. 25, no. 1, pp. 469–483, Dec. 2015.
- [6] J. Yang, Z. Lin, and S. Cohen, “Fast image super-resolution based on in-place example regression,” in Proc. IEEE Conf. Comp. Vis. Pattern Recog., Jun. 2013, pp. 1059–1066.
- [7] M. Bevilacqua, A. Roumy, C. Guillemot and M.-L. A. Morel, “Single image super-resolution via linear mapping of interpolated self-examples,” IEEE Trans. Image Process., vol. 23, no. 12, pp. 5334–5347, Dec. 2014.
- [8] C. Dong, C. C. Loy, K. He and X. Tang, “Image super-resolution using deep convolutional networks,” IEEE Trans. Pattern Anal. Mach. Intell., vol. 38, no. 2, pp. 295–307, June 2015.
- [9] H. Hyotyniemi, “Multivariate regression—Techniques and tools,” Helsinki Univ. Technology, Control Engineering Laboratory, Helsinki, Finland, Tech. Rep. 125, 2001.
- [10] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, “Image quality assessment: From error