

질감 대조 가중치를 이용한 단일 영상의 초해상도 기법

한현호
울산대학교 교양학부 조교수

Single Image Super Resolution Method based on Texture Contrast Weighting

Hyun Ho Han
Assistance Professor, College of General Education, University of Ulsan, Korea

요약 본 논문은 초해상도 결과의 품질을 향상시키기 위해 질감 특징을 세분화하여 각각을 대조하고, 그 결과를 가중치로 이용하는 초해상도 방법을 제안하였다. 초해상도에서 중요한 평가 기준인 품질의 향상을 위해서는 경계 영역과 같은 세부사항에서의 정확하고 명확한 복원 결과가 필요하며, 인공물과 같은 불필요한 잡음을 최소화하는 것이 중요하다. 제안하는 방법은 품질 향상을 위해 기존 CNN(Convolutional Neural Network) 기반의 초해상도 방법에서 특징 추정을 위해 다중 경로의 잔차 블록 구조와 skip-connection을 구성하였다. 추가적인 질감 분석을 위한 선명 및 흐림 이미지 결과를 추가로 학습하였다. 이를 활용하여 초해상도 수행 결과 또한 각각을 대조하여 가중치를 할당하는 방법을 이용해 영상의 세부사항 영역과 평활화 영역에 대해 개선된 품질을 얻을 수 있도록 하였다. 제안하는 방법의 실험 결과 평가 기준으로 활용되는 PSNR과 SSIM 값이 기존 알고리즘 대비 높은 결과 값을 얻어 품질이 개선됨을 확인할 수 있었다.

주제어 : 초해상도, 대조 가중치, CNN, 딥러닝, 질감

Abstract In this paper, proposes a super resolution method that enhances the quality of results by refining texture features, contrasting each, and utilizing the results as weights. For the improvement of quality, a precise and clear restoration result in details such as boundary areas is crucial in super resolution, along with minimizing unnecessary artifacts like noise. The proposed method constructs a residual block structure with multiple paths and skip-connections for feature estimation in conventional Convolutional Neural Network (CNN)-based super resolution methods to enhance quality. Additional learning is performed for sharpened and blurred image results for further texture analysis. By contrasting each super resolution result and allocating weights through this process, the proposed method achieves improved quality in detailed and smoothed areas of the image. The experimental results of the proposed method, evaluated using the PSNR and SSIM values as quality metrics, show higher results compared to existing algorithms, confirming the enhancement in quality.

Key Words : Super Resolution, Contrast Weighting, CNN, Deep Learning, Texture

* Corresponding Author : Hyun Ho Han(hhhan@ulsan.ac.kr)

Received February 10, 2024

Accepted March 20, 2024

Revised March 3, 2024

Published March 28, 2024

1. 서론

저해상도 영상을 이용해 고해상도 영상으로 복원하는 것인 초해상도 방법은 영상 처리 분야에서 주요 기술로 인식되고 있다. 고해상도로 복원된 영상은 시각적 품질 개선 또는 다른 영상처리 과정의 전처리 과정으로써 활용될 수 있다. 단일 영상을 활용한 초해상도의 경우 활용 범위가 다양하여 지속적으로 연구되고 있다[1].

화질이 떨어지는 저해상도 영상을 고화질로 복원하려면 전체 화소 수가 부족한 저해상도 영상의 화소 수를 고해상도 화소 수만큼 확장하고, 확장된 화소 수에 각각 적절한 값을 할당함으로써 복원을 수행하게 된다. 이 과정에서 적절한 값을 찾기 위한 방법은 값이 존재하는 주변 화소 값을 참조하여 보간법을 적용하거나 영상 내에 존재하는 유사한 영역의 정보를 활용하거나 외부의 영상 정보를 학습하여 학습된 정보를 기반으로 참조하는 방법 등이 대표적이다. 그러나 이러한 과정을 통해 생성된 초해상도 결과는 명확한 하나의 답이 존재하지 않는 문제이며, 최대한 근접한 답을 구하는 것이 목표이기에 어려운 문제 해결 과정이다.[2-4]

최근 딥러닝 기법이 등장한 이후 학습 기반의 방법에서 성능 향상이 두드러지는 결과를 보였다. CNN을 기반으로 한 딥러닝 구조의 기법들은 기존의 학습 기반의 기법 대비 복잡하고 다양한 특징 추정 및 할당이 가능하며 초해상도 생성 시 세밀한 복원 결과를 보였으며, 복잡한 패턴도 일부 복원하는 수준이 되었다[5-7]. 그러나 무작위 표본 추출 방식의 학습 과정으로 질감 등의 세부사항이 명확하게 복원되려면 많은 양의 학습이 필요하며, 다양하고 복잡한 특징 추출 방식의 특성상 인공물이 발생할 수 있다. 제안하는 방법은 영상의 질감 특징을 고려하여 정확하고 명확한 세부사항 복원을 수행하였고, 인공물의 발생도 최소화할 수 있도록 질감 특징의 대조 과정을 추가함으로써 개선된 품질의 초해상도 결과를 얻을 수 있도록 하였다.

2. 관련 연구

단일 영상을 이용한 초해상도 방법은 딥러닝 방법을 활용하여 품질을 향상하려는 방법으로 연구가 지속되고 있다. 딥러닝을 활용한 최초의 초해상도 기법인 SRCNN(Super Resolution CNN)의 등장으로 딥러닝

을 초해상도에 적용시킴으로써 기존의 보간법 및 머신러닝을 활용한 매핑 방법에 비해 향상된 성능을 보이는 것을 확인할 수 있었다[8]. 이후 CNN을 응용한 딥러닝 기반의 초해상도 방법이 다수 제안되었는데, 대표적으로 SRCNN을 통해 수행 모델의 규모가 클수록 초해상도 품질이 개선됨을 확인할 수 있었던 VDSR(Very Deep Super Resolution)이 있다[9].

DRCN(Deeply-Recursive Convolutional Network)은 매개변수의 공유를 위해 skip-connection을 갖는 재귀적 구조를 적용한 네트워크 모델이다[10]. CARN(Cascading Residual Network)은 잔차 블록에서 더 적은 매개변수를 사용하며, 캐스케이드 연결 구조를 적용한 그룹 컨볼루션을 활용해 개선된 품질을 얻고자 하였다[11]. 네트워크의 모델의 규모를 크게 함으로써 얻는 품질의 향상도 있었지만 연산량의 문제로 인해 네트워크 모델 자체를 개선하여 연산량 문제를 개선한 모델이 제안되었다. EDSR(Enhanced Deep Residual Networks Super Resolution)은 잔차 학습 과정에서의 구조를 개선함으로써 연산량 개선과 품질 향상의 결과를 보였다[12]. RDN(Residual Dense Network)에서는 잔차 학습을 재귀적으로 구성함으로써 세부정보 특징 학습이 강화되어 품질 향상의 결과를 보였다[13]. 이외에도 인코더-디코더 구조를 갖는 U-Net 기반의 방법들이 제안되었다[14]. GAN(Generative Adversarial Network) 알고리즘이 등장한 이후 GAN을 초해상도 방법에 적용시켜 품질을 개선시키려는 연구가 다수 진행되고 있다. GAN 기반의 방법들은 세부사항 정보를 보다 쉽게 얻을 수 있다는 장점이 있지만 화소 값의 오류가 발생하여 잘못된 결과를 보일 수 있어 이미지의 객관적인 품질 저하가 발생할 수 있다[15].

3. 제안하는 방법

제안하는 질감 대조 가중치를 이용한 단일 영상의 초해상도는 Fig. 1과 같은 흐름도를 갖는다. 일반적인 딥러닝 기반의 초해상도에서 효과적인 특징 추출 과정을 위해 다중 경로의 잔차 블록 구조를 적용하였고, skip-connection 구조를 적용하였다. 여기에 더해 질감 구조 별 대조 가중치를 할당하기 위해 초해상도 생성 과정 뒤 질감 대조 절차를 적용하였다.

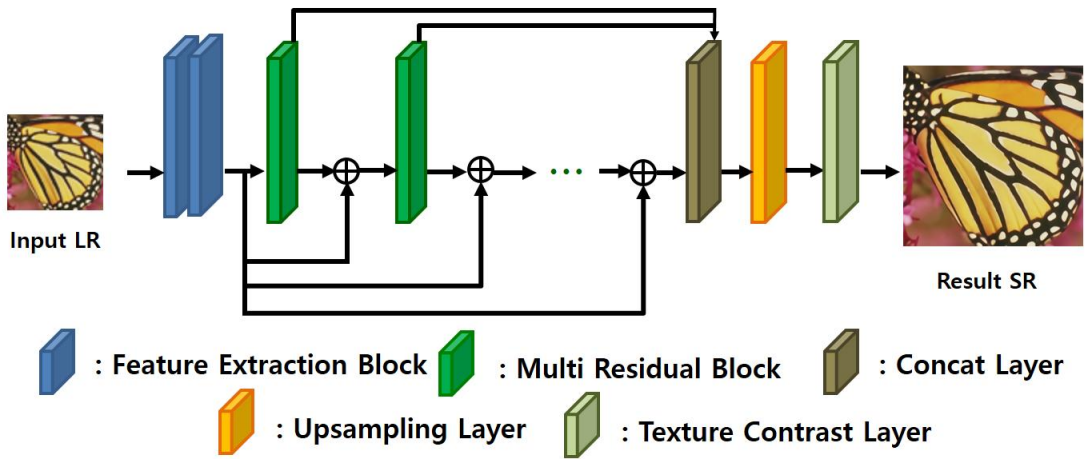


Fig. 1. Flowchart of Proposed method

3.1 특징 추출

입력된 저해상도 영상 I_{input} 으로부터 저단계 수준의 특징을 추출하기 위해 수식 (1)과 같이 3×3 컨볼루션을 2번 수행한다.

$$F_{LL} = Conv_3(Conv_3(I_{input})) \quad (1)$$

수행된 결과는 다중 경로의 잔여 블록에 적용되기 위해 각각의 블록에 skip-connection 구조로 연결된다.

다중 경로의 잔차 블록 구조는 Fig. 2와 같이 구성되어 있는데, 계층적 구조를 이용해 영상의 특징을 추정하였다.

$$F_M = (F_{MRB_n} \cdots (F_{MRB_2}(F_{MRB_1}(F_{LL}))) \quad (2)$$

$$F_{MRB_i} = \text{Concat}(\text{conv}_i(\cdots (\text{Conv}_1(F_{input}) \cdots)), SD_1, SD_2, \cdots, SD_i) \quad (3)$$

다중 경로의 잔차 블록 F_{MRB} 는 블록 내부에 컨볼루션을 수행할 때마다 각각의 수행 결과의 일부분을 분리하여 다음 컨볼루션을 수행하는 부분과 concat을 수행할 부분 S_i 로 분리하였다.

제안하는 방법에서는 다중 경로의 잔차 블록 구조

내부에 4개의 3×3 컨볼루션으로 구성하였다. 이러한 과정을 통해 다중 경로의 잔차 블록을 수행하게 되고, 이는 보다 세밀한 특징 추정이 가능하게 된다.




Fig. 2. Detail of Multi Residual Block

모든 다중 경로의 잔차 블록 과정을 수행하면 최종 concat을 수행하고, 이를 이용하여 목표하는 배율로 업샘플링을 수행함으로써 1차적인 초해상도 결과 S_f 를 생성할 수 있다.

3.2 질감 구조 별 대조 가중치 할당


1차 초해상도 결과 $S_{IN it}$ 에 질감 구조에 따른 대조된 가중치를 할당함으로써 초해상도 과정에서 문제가 되는 과적용이나 인공물 같은 사항들을 개선하고자 하였다. 대조 가중치 할당을 위해 먼저 가중 정보를 학습하기 위해 별도의 학습 과정을 거친다. 학습 과정은 먼저 저해상도 영상을 이용해 초해상도를 수행하고, 수행된 결과와 고해상도 영상에 각각 경계 중심의 결과

나타나는 고주파, 잡음을 감소하고 흐림 형태의 결과가 나타나는 저주파 대역의 정보를 추출한다. 추출된 결과의 특성을 이용할 수 있도록 경계 영역에서는 고주파 대역 H_f 의 정보를, 평활화 영역에서는 저주파 대역의 정보 L_f 를 가중할 수 있도록 학습하였다.

$$F_{area} = (H_f^* w_1, S_f^* w_2, L_f^* w_3) \quad (4)$$

가중치 w_i 를 구하기 위해 입력된 영상의 고주파, 저주파 대역을 추출하여 영역 내 존재하는 유효 화소의 개수와 형태 기준 값을 연산하고, 유효 화소의 개수와 형태 특성에 따라 특징 가중 값을 구해 각각의 대역 정보의 영역 가중치 값에 할당하였다.

이후 할당된 가중치 값을 이용하여 최종 초해상도를 생성하면 아래 Fig. 3과 같다.



(a) Input image
(b) Result of proposed method
(c) High resolution image

Fig. 3. Result of proposed method (x4)




Fig. 4 Experimental Results (x4) (a) LR (b) SRCNN (c) VDSR (d) EDSR (e) RDN (f) Proposed

4. 실험 및 결과 고찰

제안하는 방법의 실험을 위해 학습 데이터 셋으로 DIV2K dataset을 사용하였다. 학습을 위해 손실 함수로 $L1$ 을 사용하였다. 실험 데이터 셋으로는 초해상도 평가 데이터 셋으로 활용되는 BSD100, Set5, Set14을 사용하여 실험하였다. 초해상도를 수행하기 위해 원본 영상을 1/2, 1/3, 1/4의 크기로 축소한 뒤 각각에 대해 SRCNN, VDSR, EDSR, RDN, 제안하는 방법을 사용하여 원본 크기로 복원하였다.

Fig. 4는 첫 번째 줄부터 각각 set5 데이터 셋의 3번, 4번, 5번 영상이며, 저해상도 영상을 4배 초해상도한 결과이다. 3번 영상은 비교적 경계가 명확한 형태를 갖는 영상으로, 각 영역의 경계가 명확하면서도 평활화된 영역이 존재한다. SRCNN의 결과에서는 일부 흐림 현상이 남아있는 것으로 보이며, 경계 영역이 세밀하게 처리되지 않고 평활화 영역에서도 일부 인공물로 보이는 결과를 보였다. VDSR의 경우 흐림 현상은 다소 제거된 것으로 보이나 아직 남아있는 형태이고 경계 부분이 세밀하지 못한 결과를 보였다. EDSR과 RDN의 경우 시각적으로는 확연히 개선됨을 확인할 수 있으나 세밀한 부분에서 비교적 명확한 복원을 하지 못하고 부정확한 값으로 복원하였다. 제안하는 방법은 각 경계를 명확히 하고 평활화 영역에서는 가중치 반영으로 인공물이 최소화된 결과를 나타내었다.

Table 1. Quantative comparison

		PSNR Comparison			SSIM Comparison		
Model	Scale	BSD100	Set5	Set14	BSD100	Set5	Set14
SRCNN	2	31.36	36.66	32.42	0.888	0.954	0.906
VDSR		31.90	37.53	33.03	0.896	0.959	0.912
EDSR		32.32	38.11	33.85	0.901	0.960	0.920
RDN		32.34	38.24	34.01	0.902	0.961	0.921
Proposed		32.44	38.35	34.13	0.904	0.963	0.923
SRCNN	3	28.41	32.75	29.28	0.786	0.909	0.821
VDSR		28.82	33.66	29.77	0.798	0.921	0.831
EDSR		29.25	34.65	30.44	0.809	0.928	0.846
RDN		29.26	34.71	30.57	0.809	0.930	0.847
Proposed		29.35	34.86	30.73	0.813	0.933	0.850
SRCNN	4	26.90	30.48	27.49	0.710	0.863	0.750
VDSR		27.29	31.35	28.01	0.725	0.884	0.767
EDSR		27.71	32.46	28.72	0.742	0.897	0.788
RDN		27.72	32.47	28.81	0.742	0.899	0.787
Proposed		27.81	32.65	28.94	0.745	0.902	0.790

4번 영상은 경계의 폭이 매우 좁고 형태가 복잡한 영역이 존재하면서 평활화 영역같지만 세부사항이 존재하는 복잡한 형태를 가지고 있다. SRCNN의 경우 앞선 3번 영상과 같이 흐림 형상이 남아있고, 머리카락 영역에서는 입력 영상의 경계 폭이 좁기 때문에 명확히 복원되지 않고 뭉쳐진 형태의 결과를 보인다. 피부 영역 역시 마찬가지로 작은 피부 변화 영역에 대해 세밀하게 복원하지 못한 결과를 보인다. VDSR, EDSR, RDN은 비교적 매끄럽게 복원된 결과를 보이나 피부 영역과 가늘은 머리카락 영역에서는 세밀한 복원이 되지 않은 결과를 보인다. 제안하는 방법에서는 머리카락 영역과 피부 영역에서 비교적 세밀하고 매끄러운 복원 결과가 나타나는 것을 확인하였다.

5번 영상은 패턴이 복잡하면서도 평활화 영역도 존재하는 영상이다. 여기에서도 앞선 영상들과 마찬가지로 SRCNN은 흐림 형상이 남아있으면서 복잡한 모자 영역을 원활히 복원해내지 못하는 결과를 보였으며, VDSR은 복잡한 모자 영역에서 일부 뭉쳐진 결과를 갖는 형태를 보였고, EDSR과 RDN에서는 앞선 두 방법 대비 우수한 복원 결과를 보이나 제안하는 방법에 비해 일부 세밀함이 떨어지는 결과를 보였다.

제안하는 방법을 정량적 비교 측정하기 위해 PSNR(Peak Signal to Noise Ratio)과 SSIM(Structural Similarity Index Measure)을 사용하였다. PSNR은 초해상도 품질 평가를 위해 사용되는 지표로, 고해상도 영상 대비 화질 손실에 대해 잡음으로 평가하는 방식이며, 값이 높을수록 좋은 결과를 나타낸다. SSIM은 구조적 분석 평가하는 방법으로 값이 높을수록 시각적으로 유사함

을 의미한다.

Table 1은 정량적 비교 결과이다. 제안하는 방법이 기존 방법 대비 품질이 소폭 향상됨을 확인할 수 있다. 또한 확대 배율에 관계없이 품질이 향상되었음을 확인할 수 있다. 비교적 복잡한 영상 및 영상의 수가 많은 BSD100 데이터베이스에서는 PSNR, SSIM 모두 다른 데이터베이스 대비 비교적 낮은 값을 보였다.

5. 결론

본 논문은 단일 영상 초해상도 방법에서 결과의 품질을 향상시키기 위해 영상의 질감 특징을 선명-흐림 형태로 추출하여 세분화한 뒤 각각을 대조하였다. 대조한 결과를 이용하여 경계와 같은 명확히 표현될 특징에 대해 보조적인 정보를 얻었고, 평탄한 영역엔 평활화된 특징이 더 가중 적용 되어 인공물 발생을 최소화할 수 있도록 하였다. 제안하는 방법은 학습과정부터 영상에서 흔히 발견되는 고주파-저주파 대역의 정보를 포함하기 때문에 화소 값의 오류 형태를 갖는 인공물과 같은 결과를 최소화할 수 있는 장점이 있다. 실험에서 확인할 수 있듯 제안 방법이 기존 방법 대비 우수한 결과를 보였으며, 시각적 구조 또한 유지하거나 개선된 결과를 보임으로써 초해상도 결과의 품질이 향상됨을 확인할 수 있었다.

REFERENCES

[1] K. Li, S. Yang, R. Dong, X. Wang & J Huang. (2020). Survey of single image super-resolution

- reconstruction. *IET Image Processing*, 14(11), 2273-2290.
DOI : 10.1049/iet-ipr.2019.1438
- [2] Z. Lu, J. Li, H. Liu, C. Huang, L. Zhang & T. Zeng (2022). Transformer for single image super-resolution. *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 457-466).
DOI : 10.48550/arXiv.2108.11084
- [3] K. Singla, R. Pandey & U. Ghanekar. (2022). A review on Single Image Super Resolution techniques using generative adversarial network. *Optik*, 266, 169607.
DOI : 10.1049/iet-ipr.2019.1438
- [4] G. Wu, J. Jiang & X. Liu. (2023). A practical contrastive learning framework for single-image super-resolution. *IEEE Transactions on Neural Networks and Learning Systems*.
DOI : 10.1109/TNNLS.2023.3290038
- [5] K Chauhan et al. (2023). Deep learning-based single-image super-resolution: a comprehensive review. *IEEE Access*, 11, 21811-21830.
DOI : 10.1109/ACCESS.2023.3251396
- [6] C. Tian, Y. Yuan, S. Zhang, C. W. Lin, W. Zuo, D. Zhang. (2022). Image super-resolution with an enhanced group convolutional neural network. *Neural Networks*, 153, 373-385.
DOI : 10.1016/j.neunet.2022.06.009
- [7] X. Zhang, H. Zeng, S. Guo & L. Zhang. (2022, October). Efficient long-range attention network for image super-resolution. *In European conference on computer vision* (pp. 649-667). Cham: Springer Nature Switzerland.
DOI : 10.1007/978-3-031-19790-1_39
- [8] B. Liu & D. Ait-Boudaoud. (2020). Effective image super resolution via hierarchical convolutional neural network. *Neurocomputing*, 374, 109-116.
DOI : 10.1016/j.neucom.2019.09.035
- [9] J. Kim, J. K. Lee & K. M. Lee. (2016). Accurate image super-resolution using very deep convolutional networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1646-1654).
DOI : 10.1109/CVPR.2016.182
- [10] J. Kim, J. K. Lee & K. M. Lee. (2016). Deeply-recursive convolutional network for image super-resolution. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1637-1645).
DOI : 10.1109/CVPR.2016.181
- [11] N. Ahn, B. Kang & K. A. Sohn. (2018). Fast, accurate, and lightweight super-resolution with cascading residual network. *In Proceedings of the European conference on computer vision (ECCV)* (pp. 252-268).
DOI : 10.48550/arXiv.1803.08664
- [12] B. Lim, S. Son, H. Kim, S. Nah & K. Mu Lee (2017). Enhanced deep residual networks for single image super-resolution. *In Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 136-144).
DOI : 10.48550/arXiv.1707.02921
- [13] Y. Zhang, Y. Tian, Y. Kong, B. Zhong & Y. Fu (2018). Residual dense network for image super-resolution. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2472-2481).
DOI : 10.48550/arXiv.1802.08797
- [14] Z. Lu & Y. Chen. (2022). Single image super-resolution based on a modified U-net with mixed gradient loss. *signal, image and video processing*, 16(5), 1143-1151.
DOI : 10.1007/s11760-021-02063-5
- [15] M. Zhang & Q. Ling. (2020). Supervised pixel-wise GAN for face super-resolution. *IEEE Transactions on Multimedia*, 23, 1938-1950.
DOI : 10.1109/TMM.2020.3006414

한 현 호(Hyun Ho Han)

[중신회원]



- 2009년 2월 : 광운대학교 컴퓨터공학과(공학사)
- 2011년 2월 : 광운대학교 정보콘텐츠 대학원 유비쿼터스컴퓨팅학과(공학석사)
- 2019년 8월 : 광운대학교 정보디스플레이학과(공학박사)
- 2020년 3월 ~ 현재 : 울산대학교 교양학부 조교수
- 관심분야 : 무선 네트워크, 영상인식, 3D 영상처리, 기계 학습, 딥러닝
- E-Mail : hhhan@ulsan.ac.kr