

계층적 보조 경계 추출을 이용한 단일 영상의 초해상도 기법

한현호

울산대학교 교양학부 조교수

Single Image Super Resolution using sub-Edge Extraction based on Hierarchical Structure

Hyun Ho Han

Assistance Professor, College of General Education, University of Ulsan, Korea

요약 본 논문에서는 단일 영상을 기반으로 초해상도를 생성하는 과정에서 계층 구조를 거쳐 추출된 보조 경계 특징을 이용한 방법을 제안하였다. 초해상도의 품질을 향상시키기 위해서는 영상 내 경계 영역을 선명하게 표현하면서도 각 영역의 형태를 명확하게 구분하여야 한다. 제안하는 방법은 초해상도 과정에서 품질을 결정하는 중요한 요인인 경계 영역을 입력 영상의 구조적 형태를 유지하면서 개선된 초해상도 결과를 생성하기 위해 딥러닝 기반의 초해상도 방법에서 영상의 경계 영역 정보를 보조적으로 활용하는 구조를 사용하였다. 딥러닝 기반의 초해상도를 수행하기 위한 그룹 컨볼루션 구조에 더해 보조 경계 추출을 위한 고주파 대역의 정보를 기반으로 별도의 계층적 구조의 경계 누적 추출 과정을 수행하여 이를 보조 특징으로써 활용하는 방법을 제안하였다. 실험 결과 기존 초해상도 대비 PSNR과 SSIM에서 약 1%의 성능 향상을 보였다.

주제어 : 초해상도, 계층 구조, CNN, 딥러닝, 에지

Abstract In this paper, we proposed a method using sub-edge information extracted through a hierarchical structure in the process of generating super resolution based on a single image. In order to improve the quality of super resolution, it is necessary to clearly distinguish the shape of each area while clearly expressing the boundary area in the image. The proposed method assists edge information of the image in deep learning based super resolution method to create an improved super resolution result while maintaining the structural shape of the boundary region, which is an important factor determining the quality in the super resolution process. In addition to the group convolution structure for performing deep learning based super resolution, a separate hierarchical edge accumulation extraction process based on high-frequency band information for sub-edge extraction is proposed, and a method of using it as an auxiliary feature is proposed. Experimental results showed about 1% performance improvement in PSNR and SSIM compared to the existing super resolution.

Key Words : Super resolution, Hierarchical Structure, CNN, Deep Learning, Edge

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

Received November 18, 2022

Accepted December 20, 2022

Revised December 5, 2022

Published December 28, 2022

1. 서론

저해상도 영상을 고해상도로 화질을 개선할 수 있다면 시각적인 향상을 통해 영상을 통한 사람의 인지 및 판단 영역에 도움이 되고, 영상 인식 기술을 활용하는 영역에서 부족한 정보를 보완하는데 활용할 수 있을 것으로 예상할 수 있다. 이러한 효과로 인해 영상의 화질을 개선하려는 초해상도 기술이 오래전부터 연구되었으며, 최근 딥러닝 기술의 발전 및 적용으로 활발히 연구되고 있고 있다. 초해상도 기술의 적용 및 응용 분야로는 감시 영상을 통한 보안 영역과 의료 영상 분석, 비디오 품질 개선 및 다양한 컴퓨터 비전 기술 등이 있다[1,2].

초해상도 기술은 입력된 영상 정보를 이용해 상대적으로 화소 수가 많은 고해상도 영상을 만들어야 한다. 존재하지 않는 화소 값을 추정해야 하기 때문에 명확한 답이 없는 문제를 해결해야 하며, 초해상도 결과의 특성 상 품질이 떨어진다면 결과물이 만족스럽지 않거나 다른 기술에 응용하기 전 사용한 초해상도가 오히려 왜곡된 결과를 만들 수 있어 초해상도 결과의 품질을 개선하려는 연구가 지속되고 있다[3].

초해상도 결과의 품질을 개선하려면 영상의 구조적 특징을 유지하면서도 잡음이 최소화된 형태의 결과를 얻어내야 한다. 영상의 구조적 특징 및 잡음에 큰 영향을 주는 부분은 영상 내 경계 영역으로, 다른 영역과 달리 화소 값이 급변하는 곳이기 때문에 존재하지 않는 화소 값을 추정하기가 더 어렵고 추정된 결과가 만족스럽지 않게 나올 수 있어 영상 경계를 중심으로 보완하려는 연구도 다수 진행되고 있다[4]. 제안하는 방법은 초해상도 과정에서 경계 영역 화소 값 추정의 중요성을 기반으로 경계 영역 정보를 가중하여 처리하기 위해 다중 스케일의 고주파 대역의 정보로 생성된 에지 영상을 계층적 구조로 정제하여 딥러닝 기반의 초해상도 과정에 보조 특징으로써 활용하여 초해상도 결과의 품질을 개선하였다.

2. 관련 연구

단일 영상을 이용한 초해상도 방법의 시작은 표본화 이론을 활용한 단순한 형태의 선형 보간 또는 쌍삼차 보간법을 사용하였다. 고해상도 영상으로 업샘플링하는 과정에서 존재하지 않는 화소 값을 추정하기 위해 해당 화소 위치를 기준으로 주변 화소 값의 정보만을 활용하기에 고주파 대역의 세부 정보를 복원할 수 없어 초해

상도 결과의 품질이 비교적 떨어지는 결과를 보였다[5].

연구가 지속됨에 따라 학습을 기반으로 하는 방법들이 제안되었다. 초기의 학습 기반 방법은 희소성 기반 방법으로 패치 단위로 구성된 저해상도 영상과 고해상도 영상의 사전 쌍을 구성하여 학습 데이터베이스를 구성한다. 이후 입력된 저해상도 영상에서 패치 단위의 영역을 탐색하여 이에 대응하는 학습 데이터베이스의 고해상도 패치를 이용해 업샘플링을 수행함으로써 단순 화소 보간 방식 대비 품질이 뛰어난 초해상도 결과를 보였다 [6]. 이러한 학습 기반의 방식은 CNN(Convolutional Neural Network) 기반의 방법으로 발전하여 보다 고차원의 학습과 매핑 과정을 통해 초해상도 결과의 품질 향상을 보였다. 최초의 CNN 기반 초해상도는 SRCNN(Super Resolution CNN)으로 앞선 사전 쌍 형식의 학습 방법 대비 개선된 결과를 보였다. 이후 네트워크의 깊이를 깊게 설계하고 잔차 학습을 도입해 성능을 개선한 VDSR(Deep Super Resolution)이 연구되었으며, 이를 응용하거나 단점을 보완한 형태의 방법들이 다수 제안되었다[7,8]. 그러나 초해상도 결과의 품질 개선을 위해 네트워크의 깊이가 지나치게 깊어져 학습 및 수행에 필요한 연산량이 많아지는 문제가 있으며, 입력 영상에 대한 자연스러운 복원을 위한 사전 지식이 부족해 고주파 대역의 질감이나 특징을 복원하기가 어려운 문제점이 있다. 최근에는 이 문제를 개선하기 위해 초해상도 과정에서 영상 내 경계 정보를 추가적인 정보로써 활용하는 방법이 다수 제안되었다. 다양한 에지 추출 방식을 활용하여 추출된 다수의 에지 지도를 안내 지표로 활용하거나, 별도의 에지 추출 네트워크를 구성하여 개선된 에지를 추론하는 등의 연구가 진행되었다[9-11]. 추론된 에지를 활용함으로써 기존의 딥러닝 기반 방법들에서 잔차 학습과정에서의 복잡도를 비교적 줄이는 형태로 설계할 수 있으면서도 개선된 결과를 얻을 수 있다.

3. 제안하는 방법

제안하는 계층적 보조 경계 추출을 이용한 단일 영상의 초해상도 방법은 입력 영상마다의 세부 특징 복원을 위해 영상의 고주파 대역의 정보를 활용하여 보조 경계를 추출하고 추출된 보조 경계를 특징 추출 과정에서 생성된 잔차 정보에 보조 특징으로써 적용하여 영상 내 고유 질감과 특징을 복원하였다. 제안하는 방법의 흐름도는 Fig. 1과 같다.

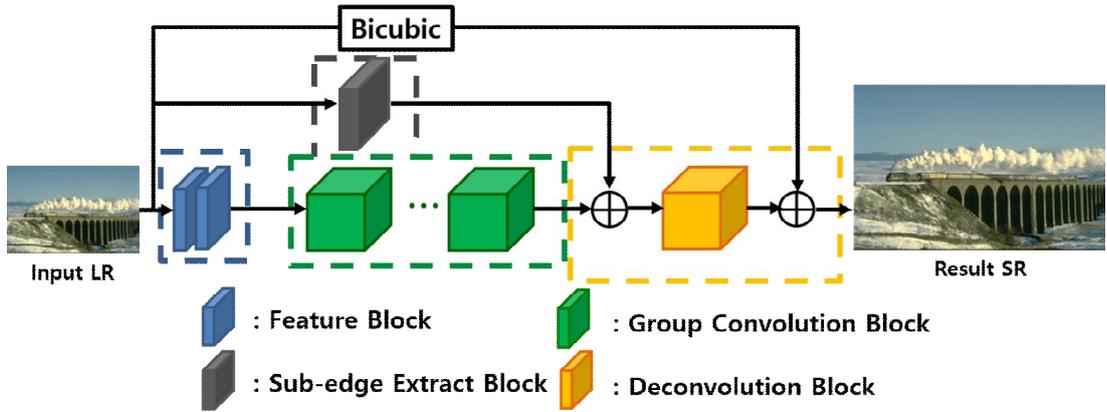


Fig. 1. Flowchart of proposed method

제안하는 방법을 수행하기 위해 저해상도 영상을 입력하고 저단계 수준의 특징 F_I 를 추출하기 위한 특징 블록 단계를 수행한다. 특징 블록 단계는 2개의 연속된 컨볼루션 블록으로 구성되어 있으며, 각각 3x3, 5x5 블록으로 구성되어 있다.

$$F_I = f_3(I_{\in put}) \oplus f_5(I_{\in put}) \quad (1)$$

수식 (1)에서 $I_{\in put}$ 은 입력 영상을, f_3, f_5 는 각각 크기에 해당하는 컨볼루션 블록을 의미한다.

이후 세부 특징 추출을 위한 그룹 컨볼루션 블록을 수행한 뒤 별도로 수행된 보조 경계 추출 블록의 정보와 결합하여 최종 특징 정보를 생성하고, 디컨볼루션 블록을 거쳐 최종 업샘플링 영상을 만들기 위해 입력 영상의 쌍삼차 보간 영상과 합성하여 최종 초해상도를 생성하였다.

3.1 그룹 컨볼루션 블록

앞선 특징 블록 단계에서 저단계 수준의 특징을 추출했다면 그룹 컨볼루션 블록에서는 앞선 특징을 심화하고 정제하는 절차를 거친다. 그룹 컨볼루션 블록은 총 4개로 구성되어 있으며, 구조는 Fig. 2와 같다.

그룹 컨볼루션의 구조는 잔차 연결 구조를 포함한 다중 컨볼루션의 가중 구조로 구성되어 있으며, 저주파 특징 맵을 추출한 뒤 가중 구조에 의한 정제로 구성되어 잡음을 최소화하는 것을 목표로 하였다.

$$F_n = C(F_p, F_{LF_n}) \quad (2)$$

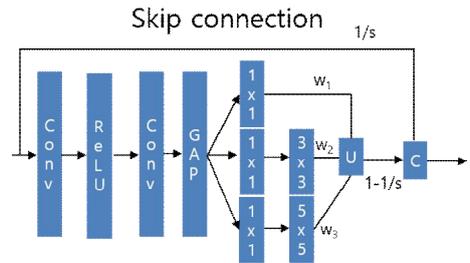


Fig. 2. Structure of group convolution block

최종 특징 맵 F_n 추출을 위한 수행 결과는 수식 (2)와 같으며, 수식 (2)에서 C 는 Concat 연산자를 의미하고 그룹 컨볼루션 과정에 해당하는 F_{LF} 는 아래 수식 (3)과 같다.

$$F_{LF} = U(C_1 * w_1, C_2 * w_2, C_3 * w_3) \quad (3)$$

수식 (3)에서 U 는 병합 연산자로 가중에 의한 합 처리 및 값 보정을 수행하고 C_1, C_2, C_3 는 각각 m 번째의 그룹 컨볼루션에서 앞선 저주파 특징 맵 추출 과정인 $GAP(Conv(ReLU(Conv(F_m))))$ 을 수행하고 나서 각각에 해당하는 컨볼루션을 수행한 것을 의미한다. 여기서 w 는 각각의 가중치 값을 의미한다.

3.2 계층적 보조 경계 추출

그룹 컨볼루션 과정을 통해 생성된 기준 특징 정보

에 입력 영상의 고주파 정보를 포함하고 경계를 명확하게 하기 위해 보조 경계를 추출한다.

고주파 대역의 정보를 추정하여 보조 경계를 구성하기 위해 입력 영상을 다중 스케일 처리를 위한 피라미드 계층 구조를 구성하고 각각에 고주파 대역 필터를 중첩 적용하는 방식으로 영상의 경계와 고주파 특징을 추출한다.

$$HFR = \sum_{n=1}^4 (HP^n(I_{\in put}) - I_{\in put} * \sigma^n) \quad (4)$$

수식 (4)에서 HFR 은 고주파 대역 특징 추출 결과를 의미하며, HP 는 고역 통과 필터, n 은 중첩 횟수, σ 는 각 중첩 결과에 대한 적용 계수이다. 각 스케일에 해당하는 고주파 대역 특징 추출 결과를 생성한다. 스케일이 작을수록 특징이 고주파 대역 특징 추출 결과에는 잡음이 다수 포함되어 있으며 불필요한 범위의 정보까지 포함한 형태의 결과가 나오기 때문에 바로 윗단계 스케일에 해당하는 특징 추출 결과와 병합하여 잡음은 줄이면서도 핵심 상세 정보를 포함할 수 있도록 하였다.

$$SF_s = RM(HFR_s, SF_s) \quad (5)$$

수식 (5)에서 SF 는 스케일에 해당하는 고주파 대역 특징 병합 결과이다. RM 은 병합을 위한 크기 재조정 및 특징 병합 함수이며, 처음 수행할 때 SF_s 는 HFR_{s+1} 로 동작하며, 가장 큰 스케일인 첫 번째 까지 수행한다. 이러한 과정을 그림으로 표현하면 Fig. 3과 같다.

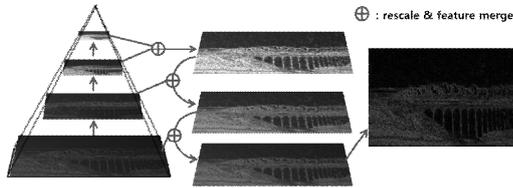


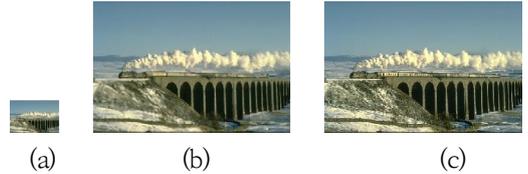
Fig. 3. Hierarchical pyramid structure for sub edge extraction

해당 작업을 수행해 최종 보조 경계 추출한 결과 값 F_{sc} 를 그룹 컨볼루션 절차의 최종 특징 맵 F_n 과 융합함으로써 디컨볼루션을 수행하기 전 적용 특징 맵을 생성한 뒤 이를 활용하여 디컨볼루션 절차 $Deconv()$ 를 수행하고 마지막 단계로 입력 영상의 쌍삼차 보간 결과

$I_{bicubic}$ 와 결합하여 최종 초해상도를 생성하게 된다.

$$I_{result} = M(Deconv(F_n, F_{sc}), I_{bicubic}, \lambda) \quad (6)$$

Fig. 4는 최종 초해상도 수행 결과이다. Fig. 4에서 (c)의 원본 고해상도 영상 대비 (b)가 (a)를 입력받아 4배의 초해상도를 수행한 결과임에도 영상 내 세부정보가 잘 표현되었음을 확인할 수 있다.



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

Fig. 4. Result of proposed method (x4)

4. 실험 및 결과 고찰

본 논문의 실험을 위해 초해상도 비교 검증을 위해 다수 활용되는 BSD-100, Set5, Set14 데이터셋을 활용하여 기존의 단순 쌍선형 보간법과 입력 영상으로 학습 사전을 구성하는 방법인 Glasner, 학습 데이터베이스 사전형 방법인 ScSR, 딥러닝 기반의 SRCNN을 제안하는 방법으로 초해상도를 수행하고 비교하였다. 비교를 위해 각 데이터셋의 영상을 2배, 3배, 4배 초해상도를 수행하기 위해 1/2, 1/3, 1/4 크기의 저해상도 영상을 생성하고 해당 영상을 입력 영상으로 사용하였다.

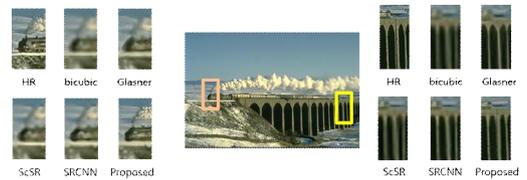


Fig. 5. Experimental result (182053 image, scale 4)

Fig. 5는 질감의 형태가 다양하고 경계선이 비교적 좁은 형태를 포함한 영상을 실험한 결과이다. 왼쪽의 기차 머리 부분의 영상에서는 단순한 보간법이나 학습 데이터베이스를 구성하는 사전형 방식에서는 비교적

영상의 흐릿함이 존재한 채 복원된 결과를 확인할 수 있으며, 딥러닝 기반의 SRCNN 방법에서는 흐릿함이 일부 개선됨을 확인할 수 있으나 명확한 경계 표현이나 질감 표현이 부족함을 확인할 수 있다. 제안하는 방법에서는 기차의 머리 부분이나 연기 부분의 선명함이 보다 개선된 형태를 보였다. 오른쪽의 다리 영역에서는 마찬가지로 기존 알고리즘에서는 흐릿함과 명확함이 상대적으로 부족함을 확인할 수 있으며, 다리 사이에 존재하는 얇은 경계면을 복원해내지 못한 것을 확인할 수 있으나 제안하는 방법에서는 경계 중심의 복원 수행 과정으로 인해 4배의 초해상도 수행 결과에서도 경계면을 복원해낸 것을 확인할 수 있다.

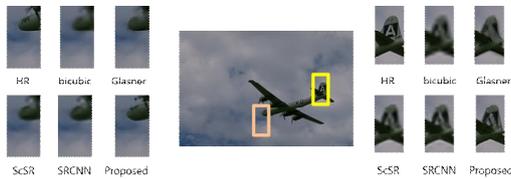


Fig. 6. Experimental result (3096 image, scale 4)

Fig. 6은 비교적 단순한 형태를 갖는 영상에 대한 실험 결과이다. 왼쪽의 비행기 머리 부분에서는 보간법이나 사전형 알고리즘들에서 흐릿함이 구름 영역에서는 비교적 적게 드러나는 형태를 보이나 비행기 머리 부분에서는 흐릿함을 가진 형태임을 확인할 수 있고 딥러닝 기반의 SRCNN에서는 비행기 머리의 형태를 흐릿함이 적은 형태로 복원하였으나 비행기 머리에 존재하는 문양의 형태가 잘 보이지 않는 것을 확인할 수 있다. 그러나 제안하는 방법에서는 문양의 형태가 비교적 뚜렷한 경계로 구분되어 화질이 개선됨을 확인할 수 있다. 오른쪽의 비행기 꼬리 부분에서는 기존 알고리즘들에서는 흐릿함을 가지고 있으며, 꼬리의 문양이 명확하게 표현되지 않는 결과를 보이나 제안하는 방법에서는 문양의 형태가 완전 복원되진 않았지만 유사한 형태로 명확하게 복원하였으며, 경계 영역이 확실하게 구분되어 비교적 화질이 개선된 것으로 보인다.



Fig. 7. Experimental result (108005 image, scale 4)

Fig. 7은 비교적 복잡하면서도 색상이 비슷한 계열인 영역과 유사한 패턴을 갖는 영역을 포함한 영상이다. 왼쪽의 나무 영역에서는 비교적 복잡한 형태를 가지면서도 색상의 차이가 크지 않아 명확한 형태 구분이 어려운 부분으로 볼 수 있다. 기존의 방법들에서는 흐릿함과 경계 영역의 모호함, 색상이 구분되지 않은 형태의 결과를 보여준다. 그러나 제안하는 방법에서는 경계가 비교적 선명하게 드러나 각 형태를 구분지어 볼 수 있으며, 풀 영역의 색상이 뭉개지지 않고 구별됨을 확인할 수 있다. 오른쪽의 호랑이 무늬 영역에서는 비교적 복잡하지 않은 단순 반복 패턴의 형태이기에 기존 알고리즘들에서는 경계 영역에서의 흐릿함이 존재함을 확인할 수 있고 제안하는 방법에서는 흐릿한 영역이 최소화된 결과로 비교적 무늬 패턴이 명확하게 구별됨을 확인할 수 있다.

초해상도 수행 결과를 정량적으로 비교하기 위해 PSNR(Peak Signal to Noise Ratio)와 SSIM(Structural Similarity Index Measure)를 수행하였으며, 각 데이터셋의 영상을 모두 수행한 뒤 평균값을 구하였다.

Table 1. Quantative comparison (PSNR)

PSNR Comparison				
Model	Scale	BSD100	Set5	Set14
Bicubic	2	29.55	33.64	29.98
Glasner		30.29	35.41	31.17
ScSR		30.77	35.72	31.44
SRCNN		31.36	36.66	32.42
Proposed		31.93	37.62	33.23
Bicubic	3	27.21	30.38	27.31
Glasner		27.07	31.08	27.99
ScSR		27.72	31.31	28.00
SRCNN		28.41	32.75	29.28
Proposed		28.93	33.96	29.89
Bicubic	4	25.98	28.42	25.77
Glasner		26.19	28.82	26.20
ScSR		26.62	29.06	26.21
SRCNN		26.90	30.48	27.49
Proposed		27.37	31.69	28.23

Table 1은 각 알고리즘의 PSNR 정량적 비교 결과이다. 값이 높을수록 좋은 결과임을 의미한다. 비교적 복잡하지 않은 데이터셋인 Set5에서는 높은 값을 가지고 복잡하고 다양한 영상이 존재하는 BSD100에서는 비교적 값이 낮은 것을 확인할 수 있다. 제안하는 방법이 기존 방법들 대비 모두 값이 높은 것을 확인할 수 있으며, 비교적 고배율인 4배율에서 성능 차이가 큰 것을 확인할 수 있다.

Table 2는 각 알고리즘의 SSIM 정량적 비교 결과이다. SSIM은 영상의 구조적 유사도를 비교하는 것으로 사람의 시각적으로 느끼는 형태의 유사함을 수치로 표현한 것이다. SSIM에서도 제안하는 방법이 모든 배율, 모든 데이터셋에서 좋은 결과를 나타내고 있으며, 고배율일수록 성능 차이가 뚜렷함을 확인할 수 있다. 이러한 결과는 영상 내에서 작거나 가늘은 형태의 경계선도 비교적 명확히 복원해내었으며, 각 영역이 명확한 경계로 구분되어 구조적으로도 식별 형태가 좋은 결과를 보였기 때문으로 추정된다.

Table 2. Quantative comparison (SSIM)

SSIM Comparison				
Model	Scale	BSD100	Set5	Set14
Bicubic	2	0.830	0.909	0.843
Glasner		0.849	0.923	0.860
ScSR		0.862	0.927	0.868
SRCNN		0.888	0.954	0.906
Proposed		0.897	0.959	0.914
Bicubic	3	0.717	0.838	0.741
Glasner		0.714	0.850	0.756
ScSR		0.744	0.856	0.764
SRCNN		0.786	0.909	0.821
Proposed		0.800	0.923	0.835
Bicubic	4	0.641	0.773	0.664
Glasner		0.647	0.781	0.675
ScSR		0.672	0.787	0.683
SRCNN		0.710	0.863	0.750
Proposed		0.727	0.888	0.771

5. 결론

본 논문은 단일 영상의 초해상도 생성 과정에서 품질 향상을 위해 계층적 보조 경계 추출을 이용한 방법을 제안하였다. 제안하는 방법은 기존 딥러닝 기반의 초해상도 방법에서 영상 내 경계 정보를 추가적인 보조 특징으로 포함하여 초해상도의 품질을 개선하고자 하였다. 이를 수행하기 위해 영상 내 경계와 윤곽 형태를 추출할 수 있도록 고주파 대역의 정보를 추정하는 계층

적 구조의 보조 경계 추출 블록을 적용하였다. 기존 딥러닝 기반의 초해상도 방법에서는 입력 영상에 대한 복원을 위해 활용하는 정보로 손실 함수 값을 최소화하는 저해상도와 고해상도 영상 간의 매핑을 학습하기 때문에 고주파 대역의 정보가 포함되지 않아 자연스러운 형태를 재구성하기에는 부족함이 있다. 제안하는 방법은 입력 영상의 고주파 대역 정보를 포함한 보조 경계 특징을 적용함으로써 영상의 윤곽과 전체적 형태가 비교적 개선된 복원 결과를 보여주었다.

REFERENCES

- [1] Y. Dun, Z. Da, S. Yang, Y. Xue & X. Qian. (2021). Kernel-attended residual network for single image super-resolution. *Knowledge-Based Systems*, 213, 106663. DOI : 10.3390/electronics10050555
- [2] F. Wang, H. Hu & C. Shen. (2021). BAM: a lightweight and efficient balanced attention mechanism for single image super resolution. *arXiv preprint arXiv:2104.07566*. DOI : 10.48550/arXiv.2104.07566
- [3] S. M. A. Bashir, Y. Wang, M. Khan & Y. Niu. (2021). A comprehensive review of deep learning-based single image super-resolution. *PeerJ Computer Science*, 7, e621. DOI : 10.1016/j.neucom.2019.09.035
- [4] 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
- [5] M. S. Sajjadi, B. Scholkopf & M. Hirsch. (2017). Enhancenet: Single image super-resolution through automated texture synthesis. *In Proceedings of the IEEE international conference on computer vision* (pp. 4491-4500). DOI : 10.48550/arXiv.1612.07919
- [6] Y. Zhang, Q. Fan, F. Bao, Y. Liu & C. Zhang. (2018). Single-image super-resolution based on rational fractal interpolation. *IEEE Transactions on Image Processing*, 27(8), 3782-3797. DOI : 10.1109/TIP.2018.2826139
- [7] C. Dong, C. C. Loy, K. He & X. Tang. (2015). Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 295-307. DOI : 10.1109/TPAMI.2015.2439281
- [8] 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
- [9] H. Liu, Z. Fu, J. Han, L. Shao, S. Hou & Y. Chu. (2019). Single image super-resolution using multi-scale deep encoder-decoder with phase congruency edge map guidance. *Information Sciences*, 473, 44-58.
DOI : 10.1016/j.ins.2018.09.018
- [10] X. Zhang, H. Zeng & L. Zhang. (2021, October). Edge-oriented convolution block for real-time super resolution on mobile devices. *In Proceedings of the 29th ACM International Conference on Multimedia* (pp. 4034-4043).
DOI : 10.1145/3474085.3475291
- [11] G. Suryanarayana et al. (2021). Accurate magnetic resonance image super-resolution using deep networks and Gaussian filtering in the stationary wavelet domain. *IEEE Access*, 9, 71406-71417.
DOI : 10.1109/ACCESS.2021.3077611

한 현 호(Hyun Ho Han)

[종신회원]



- 2009년 2월 : 광운대학교 컴퓨터 공학과(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