

단일 영상 초해상도를 위한 질감-공간 분리 기반의 특징 분류 네트워크

한현호
울산대학교 교양학부 조교수

Texture-Spatial Separation based Feature Distillation Network for Single Image Super Resolution

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

요약 본 논문은 단일 영상을 이용하여 초해상도 방법을 수행하기 위해 질감-공간 영역을 분리한 뒤 세부정보를 중심으로 특징을 분류하는 방법을 제안한다. CNN(Convolutional Neural Network) 기반의 초해상도는 세부정보를 개선하기 위한 특징 추정 과정에서의 복잡한 절차와 중복된 특징 정보의 생성으로 인해 초해상도에서 가장 중요한 기준인 품질 저하가 발생할 수 있다. 제안하는 방법은 절차적 복잡성을 줄이고 중복 특징 정보의 생성을 최소화하여 초해상도 결과의 품질을 개선하기 위해 입력 영상을 질감과 공간의 두 채널로 분리하였다. 질감 채널에서는 세부정보 복원을 위해 다중스케일로 변환한 영상에 단계별 skip-connection을 적용한 잔차 블록 구조를 적용하여 특징 정제 과정을 수행함으로써 특징 추출을 개선하였고, 공간 채널에서는 평활화된 형태의 특징을 활용하여 잡음을 제거하고 구조적 특징을 유지하도록 하였다. 제안하는 방법을 이용해 실험한 결과 기존 초해상도 방법 대비 PSNR 및 SSIM 성능 평가에서 향상된 결과를 보여 품질이 개선됨을 확인할 수 있었다.

주제어 : 초해상도, 질감, CNN, 특징 분류, 딥러닝

Abstract In this paper, I proposes a method for performing single image super resolution by separating texture-spatial domains and then classifying features based on detailed information. In CNN (Convolutional Neural Network) based super resolution, the complex procedures and generation of redundant feature information in feature estimation process for enhancing details can lead to quality degradation in super resolution. The proposed method reduced procedural complexity and minimizes generation of redundant feature information by splitting input image into two channels: texture and spatial. In texture channel, a feature refinement process with step-wise skip connections is applied for detail restoration, while in spatial channel, a method is introduced to preserve the structural features of the image. Experimental results using proposed method demonstrate improved performance in terms of PSNR and SSIM evaluations compared to existing super resolution methods, confirmed the enhancement in quality.

Key Words : Super Resolution, Texture, CNN, Feature Distillation, Deep Learning

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

Received August 8, 2023

Accepted September 20, 2023

Revised September 1, 2023

Published September 28, 2023

1. 서론

초해상도는 화질이 떨어지는 저해상도 영상을 복원하여 고해상도 영상을 생성하는 방법으로, 의료 영상이나 감시 영상, 영상 화질 복원 또는 개선 등 다양한 컴퓨터 비전 분야에 활용될 수 있다. 따라서 영상처리 분야의 주요한 기술 중 하나로 떠오르고 있다. 초해상도는 수행 결과로도 중요한 의미를 갖지만 다양한 영상처리 과정에서 초해상도를 이용한 전처리를 수행한 뒤 개선된 결과물을 만들어내는 연구 또한 다수 진행되고 있어 초해상도로 인한 확장성이 기대되는 부분이 있다. 그러므로 초해상도의 품질을 개선하기 위한 다수의 연구가 진행되고 있다[1-3].

초해상도는 입력된 저해상도 영상의 제한된 정보만을 이용해 개선된 화질의 영상을 생성하는 것으로, 적은 화소의 정보만으로 많은 화소의 정보를 생성해내려면 존재하지 않는 화소의 값을 추정하는 과정이 필요하다. 이를 위해 저해상도 영상을 고해상도 화소 수로 확장한 뒤 사이 값을 보간하기 위해 선형 보간법부터 시작하여 사전에 학습된 정보에 의한 유사성을 기반으로 보간하는 학습 방법들을 거쳐 최근의 딥러닝 기반의 방법들로 발전해왔다[4].

초해상도의 품질을 개선하기 위해서는 보간된 화소의 값이 잡음의 형태로 인식되지 않도록 적절한 값을 추정해야 하는데 일반적으로 영상 내 화소 값 변화량이 큰 경계 영역에서의 값 추정이 매우 중요하다. 또한 보간된 화소 값이 영상의 구조적 형태를 해치지 않는 결과를 보여야 한다[5]. 이러한 결과를 얻기 위해 다양한 딥러닝 기반의 알고리즘은 네트워크의 깊이를 깊게 설계하여 다양한 추정과정을 거치거나 특정한 기준을 제시할 수 있도록 하는 구조를 네트워크 내에 삽입하는 등의 방법을 제안하였다[6,7]. 그러나 이러한 방법들은 구조적, 절차적 복잡성이 문제가 되거나 중복된 특징 정보를 추정하여 최종 결과 값 생성 과정에서의 문제를 포함하는 등의 결과를 보이게 된다[8]. 제안하는 방법은 이러한 화소 값 추정 결과를 개선하기 위해 영상의 구조적 특징을 유지하면서도 추정된 화소 값을 개선하기 위해 영상의 경계 등 세부정보가 포함된 영역인 질감과 비교적 평활하여 전체적인 구조적 특징을 나타내는 공간 영역으로 분리하여 각 영역마다 별도로 구성된 절차 수행으로 상대적인 복잡성을 줄이면서 개선된 결과를 보이도록 하는 방법을 제안하였다.

2. 관련 연구

최근의 단일 영상 기반의 초해상도 방법은 딥러닝의 등장과 발전으로 인해 기존의 단순 보간 및 학습데이터 매핑 등의 방법 보다 비교적 다각도의 분석이 가능해짐으로써 초해상도의 품질이 개선되고 있다. 가장 최초의 딥러닝 기반 초해상도 방법은 CNN(Convolutional Neural Network)을 기반으로 한 SRCNN(Super Resolution CNN)이다[9]. 기존의 희소성 사전 학습에 의한 학습데이터 매핑 기반의 연구에서 딥러닝을 활용하는 방법을 처음으로 제안함으로써 초해상도 연구의 새로운 길을 제시하였다. CNN을 활용한 초해상도를 수행할 때 모델이 크고 깊을수록 초해상도의 품질이 개선될 수 있음을 제시하였고, 이러한 연구에 의해 좀 더 네트워크 구조를 깊게 설계하고 잔차 학습 과정을 적용하여 SRCNN을 개선한 VDSR(Very Deep Super Resolution)이 등장하였다[10]. VDSR 이후로 연구된 초해상도 방법은 결과의 품질을 개선시켰지만 네트워크의 깊이가 깊어진 만큼 연산량이 많아져 모델을 생성하는데 고성능의 처리기기로 긴 시간이 걸리는 문제점을 나타내게 된다. 이후 연산량의 문제를 개선하기 위해 네트워크의 구조를 수정하는 연구가 다수 이루어지는데, EDSR(Enhanced Deep Residual Networks SR)은 잔차 학습을 위한 네트워크 구조에서 배치 정규화 단계를 제거하고 각 계층의 특징 출력 수를 증가시키며 학습과정에서 다른 크기의 출력을 위해 저배수의 학습 모델을 활용하는 등의 과정을 통해 연산량을 줄이면서도 개선된 결과를 보였다[11]. 이후 제안된 RDN(Residual Dense Network)에서는 초해상도의 세부정보 특징 학습을 강화시키고자 컨볼루션 블록의 잔차 학습 과정을 재귀적으로 수행하여 초해상도 결과의 품질을 향상시켰다[12]. 이러한 연구 흐름과는 다르게 시각적 인식만을 중점으로 개선하는 방법이 아닌 명확한 세부정보 추정을 위해 새로운 필터링 방법을 제안하기도 하였다[13]. 또한 다른 방식의 구조인 U-Net을 활용하는 방법이 제안되었으며, 학습 과정의 개선을 위한 대조 학습을 제안하였다[14,15]. 따라서 최근의 연구들은 더 명확한 세부정보를 얻거나 연산량을 줄이기 위해 구조적 변경을 하거나 수행 절차에서의 특징 추출 및 정제 과정을 개선하는 추세이다.

3. 제안하는 방법

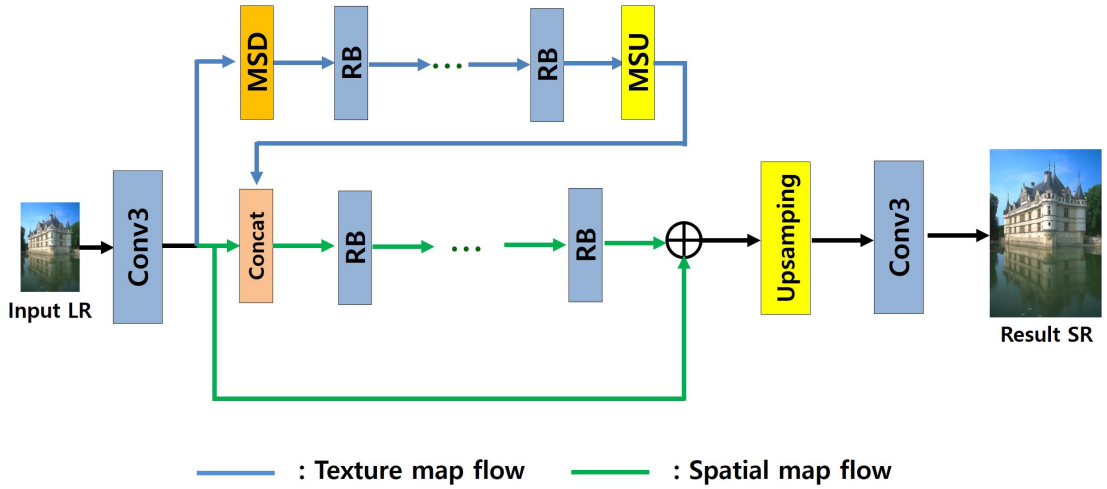


Fig. 1. Flowchart of proposed method

제안하는 단일 영상 초해상도를 위한 질감-공간 분리 기반의 특징 분류 네트워크를 구현하기 위해 Fig. 1과 같이 제안하였다. 품질이 개선된 초해상도를 생성하기 위해 입력된 저해상도 영상의 특징 추출 후 공간 영역과 질감 영역으로 분리한 뒤 많은 세부사항 정보를 포함하고 있는 질감 영역에 대해 특징 추정 과정에서 다중 스케일의 영상으로 분류해 특징 추출 후 중복되는 특징으로 인한 잡음을 제거할 수 있도록 잔차 블록 구조를 적용하였다. 이후 공간 영역의 정보는 영상 내 구조적 특징을 반영하기 위해 앞서 수행된 질감 영역의 정보에 더해 다시 잔차 블록 구조를 수행하고 생성된 결과를 초기 공간 영역 정보와 병합하는 방법을 수행하였다.

3.1 특징 추출

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

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

수행된 결과로부터 질감 영역 $F_{texture}$ 과 공간 영역 $F_{spatial}$ 을 분리하여 생성한 뒤 세부사항 정보를 추출

하기 위해 질감 영역 $F_{texture}$ 을 다중스케일의 다운 샘플링 MSD 을 수행한다.

$$F_{texture}, F_{spatial} = SEP(F_{init}) \quad (2)$$

다운샘플링된 각 스케일의 영상에 대해 잔차 블록 구조 RB 를 거쳐 질감 영역에 대한 특징 정보를 추정하였다. 잔차 블록 구조 RB 는 Fig. 2와 같이 구성되어 있다. RB 는 입력된 영상을 4개의 3×3 컨볼루션을 수행한 뒤 각각의 skip connection을 수행한 $GConv$ 를 거쳐 $Concat$ 을 수행하고 입력된 질감 영역 정보와 $Concat$ 수행 결과를 병합하는 과정을 수행한다. 다중 스케일의 잔차 블록 구조 및 skip connection을 통해 복원을 위한 세부정보의 특징이 있는 경계와 패턴 등의 정보를 추출하였다.




Fig. 2. Detail of Residual Block(RB)

이후 각각 입력된 크기로 업샘플링 을 수행한다. 앞선 과정을 통해 질감 영역의 정보를 추출하여 1차 세부 사항 정보 F_T 로 정의하였다.

$$F_T = MSU(GRB_1(MSD(F_{texture}))) \quad (3)$$

앞서 추출한 공간 영역 $F_{spatial}$ 정보와 1차 세부 사항 정보 F_T 를 *Concat*하고 공간 영역 정보가 포함된 특징을 정제하기 위해 두 번째 그룹 잔차 블록 구조 GRB_2 를 적용하였다. 이 과정을 통해 생성된 세부 사항 정보를 F_{TS} 로 정의하였다.

$$F_{TS} = GRB_2(Concat(F_T, F_{spatial})) \quad (4)$$

3.2 구조적 형태 유지 및 업샘플링

추정된 세부정보 특징 F_{TS} 는 다중스케일에 의한 추출된 특징이 누적된 경향이 있다. 이를 영상의 형태에 따라 적용함으로써 잡음 및 불특정한 결과를 줄이고자 하였다. 이를 위해 영상 내 전체적인 구조적 형태 유지를 위해 공간 영역 $F_{spatial}$ 를 이용하여 가중치표로 처리함으로써 질감 및 공간 특징에 의한 세부사항 특징 추정 결과에서 잡음 및 인공물을 제거한 최종 특징 추정 결과 F_{result} 를 생성하였다.

추정된 특징 정보를 이용해 초해상도를 수행하기 위한 업샘플링 및 원 영상의 형태로 변환하기 위한 컨볼루션을 수행하면 Fig. 3과 같은 최종 초해상도 수행 결과를 얻을 수 있다.



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

Fig. 3. Result of proposed method (x4)

4. 실험 및 결과 고찰

본 논문의 실험을 위해 DIV2K dataset을 학습 데이터 셋으로 활용하였다. 학습을 위해 손실 함수로 $L1$ 을 사용하였다. 기존의 제안된 딥러닝 기반의 초해상도 알고리즘인 SRCNN, VDSR, EDSR, RDN을 제안하는 방법과 비교하기 위해 품질 평가 데이터 셋으로 활용되는 BSD100, Set5, Set14의 영상에 초해상도를 수행하였다. 초해상도를 수행하기 위해 원본 고해상도 영상을 1/2, 1/3, 1/4 크기로 쌍입방 보간법을 사용하여 축소 한 뒤 각각에 대해 원본 크기로 복원하였다.

Fig. 4는 영상 내 구조물의 형태가 명확하고 그 내부의 세부사항들이 다수 존재하는 유형의 영상에 대해 각 알고리즘으로 4배의 초해상도를 실험한 결과이다. 기존의 초해상도 방법 중 SRCNN과 VDSR에서는 경계가 명확하지 않고 비교적 흐려진 형태를 가져 영상이 전체적으로 흐리게 복원되었음을 확인할 수 있다. EDSR과 RDN의 경우 앞선 알고리즘들에 비해 일부 개선된 결과를 보이나 비교적 높은 배수의 초해상도를 수행하기 때문에 발생하는 원본 영상과 유사한 형태로 복원하지 못하고 특정 영역의 형태를 유지하지 못한 채 부정확한 값으로 복원하는 등의 문제를 보이는 것을 확인할 수 있다. 제안하는 방법에서는 창과 지붕의 경계가 명확히 구분되어 있고 창틀의 색이 비교적 원본영상에 가깝게 복원되었으며, 원본 영상과 구조적으로 가장 유사한 형태의 결과를 보인 것을 확인할 수 있다.




Fig. 4. Experimental result (102061 image, scale 4)



Fig. 5. Experimental result (147091 image, scale 4)

Fig. 5는 평활화된 영역과 복잡한 세부사항이 모두 존재하는 영상에 대해 실험한 결과이다. 영상의 특성상 평활화된 영역에서는 명확한 영역 별 구분이 필요하고, 세부사항의 경우 각 경계와 색상에 대한 정확도 높은 복원이 필요하다. 기존의 알고리즘인 SRCNN과 VDSR에서는 전체적으로 흐린 형태를 보여 평활화된 영역에서도 명확한 구분이 되지 않고 경계가 많은 영역은 일부가 복원되지 않거나 비교적 명확한 경계 구분이 되지 않는 것을 확인할 수 있다. EDSR에서는 흐림 현상이 일부 개선되었으나 높은 배율의 초해상도에서의 명확한 경계 생성에는 어려움을 보인다. RDN과 제안하는 방법은 비교적 명확한 경계면 형성을 보이며, 제안하는 방법에서는 색상 경계가 비교적 뚜렷함을 확인할 수 있다.




Fig. 6. Experimental result (253027 image, scale 4)

Fig. 6은 경계가 명확하고 좁은 영역 내에 반복된 패턴이 존재하는 유형의 영상에 대해 실험한 결과이다. 이 영상의 경우 패턴 사이의 경계를 명확히 구분하고 패턴의 크기와 형태가 원본 영상과 유사하게 복원을 하는 것이 중요하다. 기존에 제안된 SRCNN의 경우 계단 현상이 일부 확인되며 흐려짐 현상이 포함되었고,

VDSR은 계단 현상은 없으나 패턴이 휘어진 부분에서 흐려짐이 다수 발견된다. EDSR과 RDN의 경우 흐려짐 부분은 개선되었으나 패턴의 형태가 휘어진 부분에서 사이 공간이 보간 돼 곡선의 경계가 직선에 가깝게 복원된 결과를 보인다. 제안하는 방법에서는 곡선의 경계 부분에서도 원본 영상과 유사하게 복원되었음을 확인할 수 있으며, 비교적 명확한 경계로 구분되어 표현되었음을 확인할 수 있다.

제안하는 방법과 기존 방법의 정량적 비교를 위해 초해상도 품질 평가 기준으로 사용되는 화질 손실 평가 부분의 PSNR(Peak Signal to Noise Ratio)과 시각적 평가를 위한 구조적 정보를 분석하여 비교하는 SSIM(Structural Similarity Index Measure)을 사용하였다. 각각의 실험 데이터셋에 포함된 다수의 영상에 대해 초해상도를 모두 수행하고 전체 영상의 PSNR과 SSIM 평균을 구하였다.

Table 1은 PSNR 정량적 비교 결과이다. PSNR 평가는 값이 높을수록 원본 영상 대비 화질 손실이 적은 것을 의미한다. 영상의 수가 많고 비교적 영상 내 복잡한 형태가 존재하는 BSD100 데이터 셋의 경우 다른 데이터 셋 대비 초해상도 배수에 관계 없이 전체적으로 PSNR 값이 떨어지는 것을 확인할 수 있다. 제안하는 방법이 기존 알고리즘 대비 모든 배율에서 소폭 향상된 결과를 보였다.

Table 1. Quantative comparison (PSNR)

PSNR Comparison				
Model	Scale	BSD100	Set5	Set14
SRCNN	2	31.36	36.66	32.42
VDSR		31.90	37.53	33.03
EDSR		32.32	38.11	33.85
RDN		32.34	38.24	34.01
Proposed		32.42	38.31	34.09
SRCNN	3	28.41	32.75	29.28
VDSR		28.82	33.66	29.77
EDSR		29.25	34.65	30.44
RDN		29.26	34.71	30.57
Proposed		29.32	34.81	30.69
SRCNN	4	26.90	30.48	27.49
VDSR		27.29	31.35	28.01
EDSR		27.71	32.46	28.72
RDN		27.72	32.47	28.81
Proposed		27.79	32.62	28.92

Table 2. Quantative comparison (SSIM)

SSIM Comparison				
Model	Scale	BSD100	Set5	Set14
SRCNN	2	0.888	0.954	0.906
VDSR		0.896	0.959	0.912
EDSR		0.901	0.960	0.920
RDN		0.902	0.961	0.921
Proposed		0.903	0.962	0.922
SRCNN	3	0.786	0.909	0.821
VDSR		0.798	0.921	0.831
EDSR		0.809	0.928	0.846
RDN		0.809	0.930	0.847
Proposed		0.811	0.931	0.849
SRCNN	4	0.710	0.863	0.750
VDSR		0.725	0.884	0.767
EDSR		0.742	0.897	0.788
RDN		0.742	0.899	0.787
Proposed		0.744	0.901	0.789

Table 2는 SSIM 정량적 비교 결과이다. SSIM은 영상의 구조 정보를 고려하여 변화의 정도를 비교하는 것으로 사람이 느끼는 시각적 부분의 평가이다. SSIM 평가 또한 값이 높을수록 원본 영상 대비 구조 정보가 변화되지 않아 원본 영상의 품질에 가까운 것을 의미한다. SSIM 평가 또한 제안하는 방법에서 모든 초해상도 배수 및 데이터 셋에 대해 소폭 향상된 결과를 나타낸다. 제안하는 방법이 경계나 형태 부분에서 비교적 개선된 복원 결과를 보여 영상의 구조 변화가 적은 것으로 판단된다.

5. 결론

본 논문은 단일 영상을 이용한 초해상도를 생성하기 위해 입력 영상을 질감과 공간 영역으로 분리한 뒤 각각의 절차를 거쳐 특징 분류를 수행하는 방법을 제안하였다. 제안하는 방법은 기존의 딥러닝 기반 초해상도에서의 품질 개선을 위해 입력 영상으로부터 핵심 세부정보 중심의 질감 영역과 구조적 특징을 유지하는 공간 영역으로 분리함으로써 중복된 특징 추출을 감소시키고자 하였다. 각 영역의 분리 접근을 통해 상대적으로 구조적인 복잡성을 줄이면서도 초해상도 과정에서 중요한 경계 등의 세부정보를 품질이 개선된 형태로 복원하는 것을 확인할 수 있었다. 또한 영상의 구조적 특징을 유지하는 별도의 공간 영역 절차를 통해 초해상도 생성 결과가 경계 등의 세부 영역에 더해 영상의 전체적 형태를 유지함으로써 시각적으로도 개선됨을 확인할 수 있었다.

REFERENCES

- [1] H. Chen, X. He, L. Qing, Y. Wu, C. Ren, R. E. Sheriff & C. Zhu. (2022). Real-world single image super-resolution: A brief review. *Information Fusion*, 79, 124-145. DOI : 10.1016/j.inffus.2021.09.005
- [2] Y. Zhang, Y. Huang, K. Wang, G. Qi & J. Zhu. (2023). Single image super-resolution reconstruction with preservation of structure and texture details. *Mathematics*, 11(1), 216. DOI : 10.3390/math11010216
- [3] Z. Hui, J. Li, X. Gao & X. Wang. (2021). Progressive perception-oriented network for single image super-resolution. *Information Sciences*, 546, 769-786. DOI : 10.1016/j.ins.2020.08.114
- [4] B. Niu et al. (2020). Single image super-resolution via a holistic attention network. *In Computer Vision-ECCV 2020: 16th European Conference, Glasgow, UK, August 23-28, 2020, Proceedings, Part XII 16* (pp. 191-207). Springer International Publishing. DOI : 10.1007/978-3-030-58610-2_12
- [5] F. Fang, J. Li & T. Zeng. (2020). Soft-edge assisted network for single image super-resolution. *IEEE Transactions on Image Processing*, 29, 4656-4668. DOI : 10.1109/TIP.2020.2973769
- [6] M. Haris, G. Shakhnarovich & N. Ukita, (2020). Deep back-project networks for single image super-resolution. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(12), 4323-4337. DOI : 10.1109/TPAMI.2020.3002836
- [7] 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
- [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] 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

- [10] 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
- [11] B. Lim, S. Son, Kim, H., Nah, S., & Mu Lee, K. (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
- [12] 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
- [13] Y. Huang, J. Li, X. Gao, Y. Hu & W. Lu. (2021). Interpretable detail-fidelity attention network for single image super-resolution. *IEEE Transactions on Image Processing*, 30, 2325-2339.
DOI : 10.1109/TIP.2021.3050856
- [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*, 1-9.
DOI : 10.1007/s11760-021-02063-5
- [15] 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

한 현 호(Hyun Ho Han)

[증신회원]



- 2009년 2월 : 광운대학교 컴퓨터공학과(공학사)
- 2011년 2월 : 광운대학교 정보콘텐츠대학원 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