

논문 2020-15-08

# 딥 러닝 기반의 초해상도 이미지 복원 기법 성능 분석 (Performance Analysis of Deep Learning-based Image Super Resolution Methods)

이 현 재, 신 현 광, 최 규 상\*, 진 성 일\*

(Hyunjae Lee, Hyunkwang Shin, Gyu Sang Choi, Seong-Il Jin)

Abstract : Convolutional Neural Networks (CNN) have been used extensively in recent times to solve image classification and segmentation problems. However, the use of CNNs in image super-resolution problems remains largely unexploited. Filter interpolation and prediction model methods are the most commonly used algorithms in super-resolution algorithm implementations. The major limitation in the above named methods is that images become totally blurred and a lot of the edge information are lost. In this paper, we analyze super resolution based on CNN and the wavelet transform super resolution method. We compare and analyze the performance according to the number of layers and the training data of the CNN.

Keywords : Single image super-resolution, Deep learning, Wavelet transforms

## 1. 서 론

최근 의학, 지리학, 디스플레이 등 다양한 분야에서 단일 영상 초해상도 (Single Image Super-Resolution)에 대한 연구가 활발히 이루어지고 있다. 단일 영상 초해상도는 저해상도 (Low Resolution) 영상에 비해 다양한 정보를 제공함으로써 정교한 분석과 처리를 요구하는 분야에서 큰 역할을 담당하고 있다. 그러나 초기에 고가의 장비를 통해 초해상도 영상을 획득할 수 있기 때문에 높은 비용이 요구된다 [1, 2]. 따라서, 높은 비용 문제를 해결하기 위해 저가의 장비로부터 입력받은 저해상도 영상을 초해상도 영상으로 복원하는 기술들이 주목받고 있다 [3].

기존의 초해상도 복원기법에서 보편적으로 사용

\*Corresponding Author(castchoi@ynu.ac.kr, sijin@cnu.ac.kr)

Received: Feb. 3, 2020, Revised: Mar. 23, 2020, Accepted: Mar. 27, 2020.

H. Lee: Erae AMS (Engineer)

H. Shin: Yeungnam University (Ph.D. Student)

G.S. Choi: Yeungnam University (Assoc. Prof.)

S.I. Jin: Chungnam National University (Prof.)

※ 본 연구는 충남대학교 학술연구비에 의해 지원되었음.

되는 영상 보간법 중 하나인 고등차수 보간법 (Bicubic Interpolation) [4]은 하나의 픽셀값을 결정하기 위해 인접한 16개 픽셀을 고려하여 하나의 픽셀값을 결정한다. 그 외 보간법은 최근접 보간법 (Nearest Neighbor Interpolation), 양선형 보간법 (Bilinear Interpolation) 등이 사용되며, 저해상도의 영상의 크기를 업샘플링 (Upsampling)하여 선형 필터를 통해 영상을 복원한다. 하지만 기존의 복원기법은 고주파 영역을 복원함에 있어 오차가 크다는 단점을 가지고 있다 [5]. 최근 이러한 한계점을 해결하기 위해 딥 러닝 기술을 적용하는 연구가 진행되고 있다. 딥 러닝 기반의 초해상도 기술은 합성곱 신경망 (Convolutional Neural Network)과 같은 딥 러닝 모델을 이용하여 고해상도 영상을 복원한다 [6, 7]. 합성곱 신경망을 이용한 대표적인 초해상도 복원기법으로 SRCNN (Super Resolution Convolutional Neural Network) [8], VDSR (Very Deep Super Resolution) [9] 등이 있다. SRCNN은 특징 추출, 비선형 매핑 (Mapping), 복원 역할을 하는 계층 (Layer)으로 3개의 계층으로 구성되며, 기존의 영상 보간법들에 비해 높은 복원 성능을 달성했다. 하지만, 경사 하강법 (Gradient Descent)의 학습률 (Learning rate)을  $10^{-5}$ 로 학습하기 때문에 학습 시간이 오래 걸리며, 낮은 계층 (3계층)으로 구성되어있기 때문에 성능이 저하되는




그림 1. SRCNN의 구조

Fig. 1 Structure of SRCNN

문제가 존재한다. Kim은 기존 SRCNN의 문제를 개선한 VDSR라는 초해상도 복원기법을 제안했다. VDSR은 필터의 계수를  $3 \times 3$ 으로 하고, 총 계층의 수를 20계층으로 구성했으며, SRCNN의 학습률보다 1만 배 높게 적용함으로써 학습 시간 단축과 성능을 개선했다. 합성곱 신경망을 이용한 초해상도 복원기법들이 연구되고 있지만, 고주파 영역을 복원하는데 많은 어려움이 존재한다. 이러한 문제를 해결하기 위해 최근 고주파 영역을 복원하는 웨이블릿 변환 기반의 초해상도 복원 연구들이 진행되고 있다.

본 논문에서는 기존의 합성곱 신경망 기반의 초해상도 복원 기법 (VDSR)과 웨이블릿 변환 기반의 초해상도 복원 기법 (DWSR, ISSR)에 대해 계층 수, 학습 데이터 수에 따른 성능에 대해 비교 분석하며, 논문의 구성은 다음과 같다. 2장에서는 합성곱 신경망 기반의 초해상도 기법인 SRCNN, VDSR에 대해 설명하며, 3장에서는 웨이블릿 변환 기반의 초해상도 복원기법인 DWSR (Deep Wavelet Super-Resolution) [10], ISSR (Individual Sub-band Super-Resolution) [11]에 대해 설명한다. 4장은 실험 환경에 대해 설명하며, 5장에서 기존의 초해상도 복원기법에 대한 성능을 비교 및 분석한다. 마지막으로 6장에서 결론을 맺는다.

## II. 합성곱 신경망 기반의 초해상도 복원기법

### 1. SRCNN

SRCNN은 초해상도 영상 복원 분야에서 최초로 딥 러닝을 적용한 연구로 널리 알려졌으며, SRCNN의 구조는 그림 1과 같다. 첫 번째 계층에서는 저해상도 영상 ( $X$ )의 특징 벡터 ( $F$ )를 추출하는 단계이

며, 식 (1)을 통해 특징을 추출한다.

$$F_1(X) = \max(0, W_1 * X + B_1) \quad (1)$$

$W_1$ 과  $B_1$ 은 필터의 계수와 편향 (bias)을 의미하며, '\*'은 합성곱 연산을 나타낸 것이다. 입력 이미지의 채널과 필터 계수에 의해  $W_1$ 의 차원이 결정되며, 합성곱 연산의 값을 활성화 함수 ReLU ( $\max(0, x)$ )에 적용함으로써, 특징을 추출한다. 두 번째 계층에서는 추출된 특징들과 대응하는 고해상도 특징들을 찾는 단계이며, 식 (2)를 통해 다른 차원으로 매핑한다.

$$F_2(X) = \max(0, W_2 * F_1(X) + B_2) \quad (2)$$

$W_2$ 의 차원은 식 (1)의 결과와 두 번째 계층의 필터 계수에 따라 결정되며, 마지막 계층에서는 식 (2)에서 추출된 특징 벡터를 통해 고해상도 영상을 복원한다. 마지막 계층의 연산은 식 (3)과 같다.

$$F(X) = W_3 * F_2(X) + B_3 \quad (3)$$

SRCNN은 학습 데이터로 ILSVRC (ImageNet Large Scale Visual Recognition Competition) [12]에서 제공한 데이터셋을 사용했으며, 초해상도 영상 (H)과 SRCNN을 통해 복원된 영상 간의 손실 함수 (Loss function)로 평균 제곱 오차 (Mean Squared Error)를 사용했다.

$$L(\theta) = \sum_n^1 \|F(X_i; \theta) - H_i\|^2 \quad (4)$$

하지만 SRCNN은 더 깊은 네트워크 계층으로 구성할 시, 초해상도 복원 성능 저하 및 영상의 엣지 (edge) 영역을 복원하지 못하는 문제가 존재한다 [13].




그림 2. VDSR의 구조  
Fig. 2 Structure of VDSR

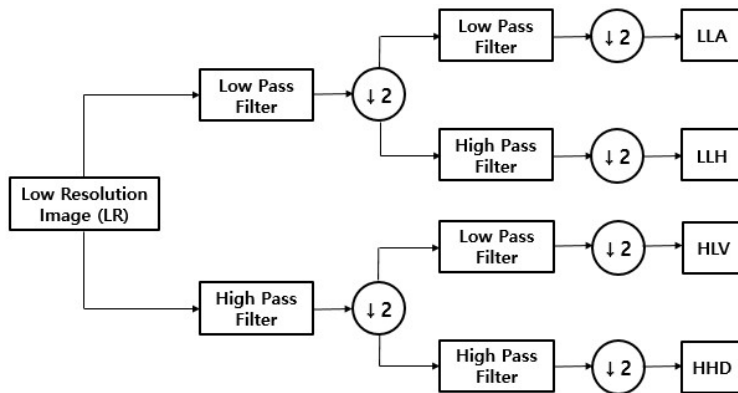


그림 3. 1-레벨 2차원 이산 웨이블릿 변환 절차  
Fig. 3 The procedure of 1-level 2dDWT (2d Discrete Wavelet Transformation)

## 2. VDSR

VDSR은 깊은 계층으로 구성되어 초해상도 영상 복원 성능을 개선했으며, 구조는 그림 2와 같다. 이 신경망의 구조는 20계층으로 이루어지며, 입력은 특정 스케일 (scale)로 보간된 저해상도 영상, 출력은 고해상도 영상 복원에 필요한 고주파 신호가 출력된다. 즉, VDSR은 저해상도 영상과 고해상도 영상 간의 고주파 신호를 잔차학습 (Residual Learning) [14]하여, 고주파 신호를 학습하고 저해상도 영상과 출력된 고주파 신호의 합으로 초해상도 영상 복원한다. 첫 번째 계층과 마지막 계층은  $3 \times 3 \times 64$  크기의 단일 필터로 구성되며, 그 외 계층은  $3 \times 3 \times 64$  크기의 필터를 64개 사용한다. 하지만 합성곱 연산을 통해 획득되는 이미지 크기가 입력 영상 크기보다 작아짐으로써 테두리 부분이 복원되지 않는 문제가 발생한다. 이러한 문제를 VDSR에서는 합성곱 연산을 수행하기 전 테두리에 0의 값을 추가하는 제로 패딩 (zero-padding)을 사용함으

로써, 입력과 출력 영상의 공간적 크기를 유지했다.

VDSR의 학습을 위한 데이터셋은 총 291개 데이터를 사용했으며, BSD68 (Berkeley Segmentation Dataset) [15]의 200개 데이터와 Yang [16]의 91개 데이터를 사용했다. 또한, 테스트를 위한 데이터셋으로 Set5 [17], Set14 [18] 등을 사용하여 초해상도 복원 성능을 검증했으며, SRCNN 보다 성능이 우수함을 증명했다. 그러나 블러 (blur) 및 평탄화 현상에 의해 출력 영상의 고주파 정보가 손실되는 문제가 존재한다 [13].

## III. 웨이블릿 변환 기반의 초해상도 복원기법

본 장에서는 2차원 웨이블릿 변환 (Discrete Wavelet Transformation) 방법에 대해 간략히 설명하고, 웨이블릿 변환 기반의 초해상도 복원기법인 DWDR과 ISSR에 대해 설명한다.

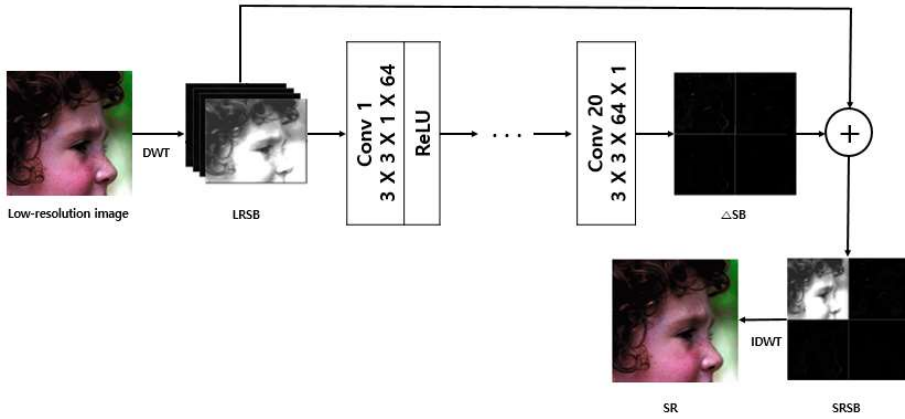


그림 4. DWSR의 구조

Fig. 4 Structure of DWSR

2차원 웨이블릿 변환은 각 스케일을 통해 4개의 서브 밴드 (Sub band)로 나누어지며, 1-레벨 2차원 이산 웨이블릿 변환 절차는 그림 3과 같다. 1-레벨 2차원 이산 웨이블릿 변환 절차는 입력 영상이 주어지면 저역 필터 (Low-pass filter)와 고역 필터 (high pass filter)를 거치게 되며, 각 영상은 1/2 크기로 줄어든다. 그 후, 1/2 크기로 줄어든 각 영상들은 저역 필터 및 고역 필터를 거치게 되며 서브 밴드 계수에 해당하는 평균 (LLA), 수평 (LLH), 수직 (HLV), 대각선 (HHD) 4개의 서브 밴드 영상이 생성된다. 원영상은 4개의 서브 밴드 영상에 역 웨이블릿 변환을 적용하여 복원이 가능하다 [19].

### 1. DWSR

DWSR은 기존 VDSR 기법에 웨이블릿 변환을 적용한 초해상도 복원기법을 제안했으며, 구조는 그림 4와 같다. 기존의 영상에 비해 웨이블릿 서브 밴드는 많은 구조 정보를 추론하는데 사용할 수 있다. 따라서, 고해상도 서브 밴드와 저해상도 서브 밴드 간의 차이  $\Delta SB$ 를 학습시킴으로써 초해상도 영상을 예측할 수 있다. DWSR 입력은 4개의 저해상도 서브 밴드 (LRSB)를 생성하기 위해 웨이블릿 변환을 하며, 식 (5)와 같이 표현된다.

$$\begin{aligned} \text{LRSB} &= \{\text{LLA}, \text{LHLV}, \text{LLLH}, \text{LHHD}\} \\ &:= \text{DWT}\{\text{LR}\} \end{aligned} \quad (5)$$

저해상도 서브 밴드는 저해상도 이미지 LR (Low-resolution image)을 이산 웨이블릿 변환 DWT (Discrete Wavelet Transformation)를 통해

LLLA, LHLV, LLLH, LHHD 생성되며, 평균, 수직, 수평, 대각선에 대한 웨이블릿 계수를 포함한다. 또한, 4개의 고해상도 서브 밴드 (HRSB)는 식 (6)과 같이 웨이블릿 변환을 통해 생성한다.

$$\begin{aligned} \text{HRSB} &= \{\text{HLLA}, \text{HHLV}, \text{HLLH}, \text{HHHD}\} \\ &:= \text{DWT}\{\text{HR}\} \end{aligned} \quad (6)$$

고해상도 서브 밴드는 HLLA, HLLH, HHLV, HHHD로 구성되며, 고해상도 영상의 평균, 수직, 수평, 대각선에 대한 웨이블릿 계수를 포함한다. 식 (7)은 고해상도 서브 밴드와 저해상도 서브 밴드 간의 잔여 차이  $\Delta SB$ 를 구하는 수식을 나타낸 것이다.

$$\begin{aligned} \Delta SB &= \text{HRSB} - \text{LRSB} \\ &= \{\text{HLLA} - \text{LLA}, \text{HLLV} - \text{LHLV}, \\ &\quad \text{HLLH} - \text{LLLH}, \text{HHHD} - \text{LHHD}\} \\ &= \{\Delta A, \Delta V, \Delta H, \Delta D\} \end{aligned} \quad (7)$$

초해상도 영상 복원하기 위해 LRSB를 입력하여  $\Delta SB$ 를 생성한다. 그 후, 식 (8)과 같이 계산하여, 초해상도의 서브 밴드 (SRSB)를 생성한다.

$$\begin{aligned} \text{SRSB} &= \{\text{SRA}, \text{SRV}, \text{SRH}, \text{SRD}\} \\ &= \text{LRSB} + \Delta SB \end{aligned} \quad (8)$$

마지막 단계에서는 역 웨이블릿 변환 IDWT (Inverse Discrete Wavelet Transformation)을 통해 초해상도 영상을 복원한다.

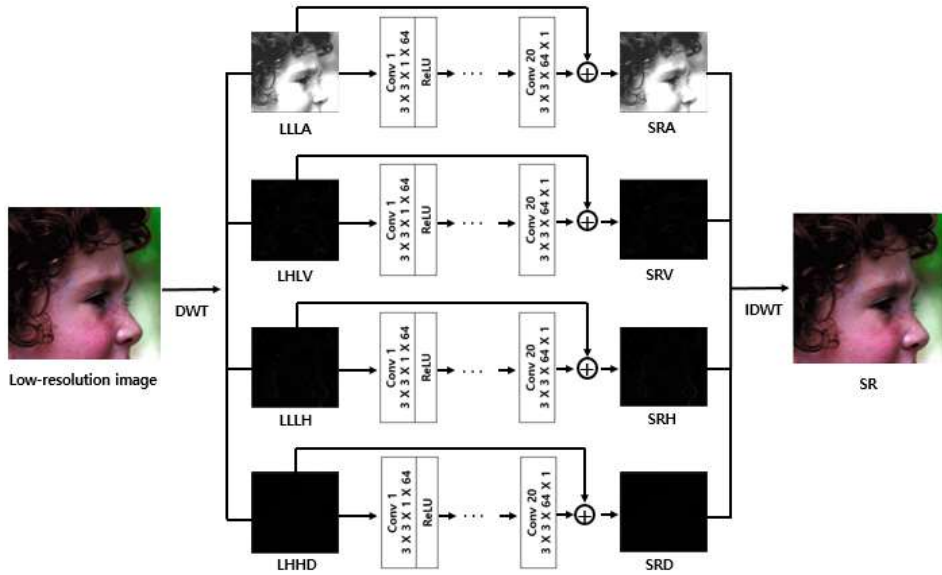


그림 5. ISSR의 구조  
Fig. 5 Structure of ISSR




그림 6. 데이터 전처리의 예  
Fig. 6 Example of data Pre-processing

$$SR = IDWT\{SRSB\} \quad (9)$$

학습을 위한 데이터셋은 추가적인 데이터를 활용하지 않고, NTIRE [20] 800 데이터셋을 사용했으며, VDSR에서 발생하는 블러 및 고주파 성분 손실 문제를 해결했다. 또한, 저해상도 서브 밴드를 입력으로 사용하기 때문에 학습 시간과 실행시간이 VDSR에 비해 2배 이상 빠르다.

## 2. ISSR

ISSR은 웨이블릿 변환을 적용한 DWSR과 유사하며, 각 서브 밴드 주파수 성분들을 독립적으로 학

습했다. 그림 5는 ISSR의 구조이며, 저해상도 서브 밴드와 고해상도 서브 밴드는 DWSR과 동일하게 방법으로 생성된다. 각 저해상도 서브 밴드 주파수 성분은 입력으로 사용하며, 식 (10)은 고해상도 서브 밴드와 저해상도 서브 밴드 간의 잔여 차이  $\Delta A, \Delta V, \Delta H, \Delta D$ 를 구한다.

$$\begin{aligned} \Delta A &= HLLA - LLLA \\ \Delta V &= HLLV - LHLV \\ \Delta H &= HLLH - LLLH \\ \Delta D &= HLLD - LHHD \end{aligned} \quad (10)$$

그 후, 식 (11)과 같이 계산하여, 각 주파수 성분에 대한 초해상도의 서브 밴드 SRA, SRV, SRH, SRD를 생성한다.

$$\begin{aligned} SRA &= LLLA + \Delta A \\ SRV &= LHLV + \Delta V \\ SRH &= LLLH + \Delta H \\ SRD &= LHHD + \Delta D \end{aligned} \quad (11)$$

마지막 단계에서는 식 (12)을 통해 초해상도 영상을 복원한다.

$$SR = IDWT\{SRA, SRV, SRH, SRD\} \quad (12)$$

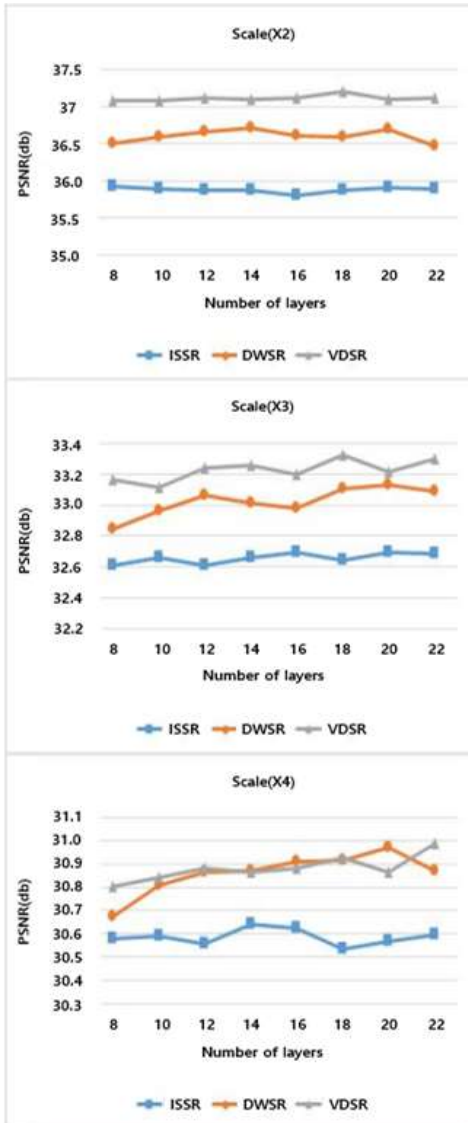


그림 7. 계층 수 변화에 따른 스케일 ( $\times 2$ ,  $\times 3$ ,  $\times 4$ )의 성능 비교

Fig. 7 Performance comparison of scale ( $\times 2$ ,  $\times 3$ ,  $\times 4$ ) according to the number of layers

#### IV. 실험 환경

본 논문의 실험은 Python 2.7 기반의 Tensorflow를 사용하여 성능을 평가했으며, 학습 파라미터는 패치 크기 (Patch size)  $41 \times 41$ , 배치 크기 (Batch size) 64, L2 정규화 (L2 Regulator) 10-4, 학습률 10-3, Adam Optimizer를 사용했다.

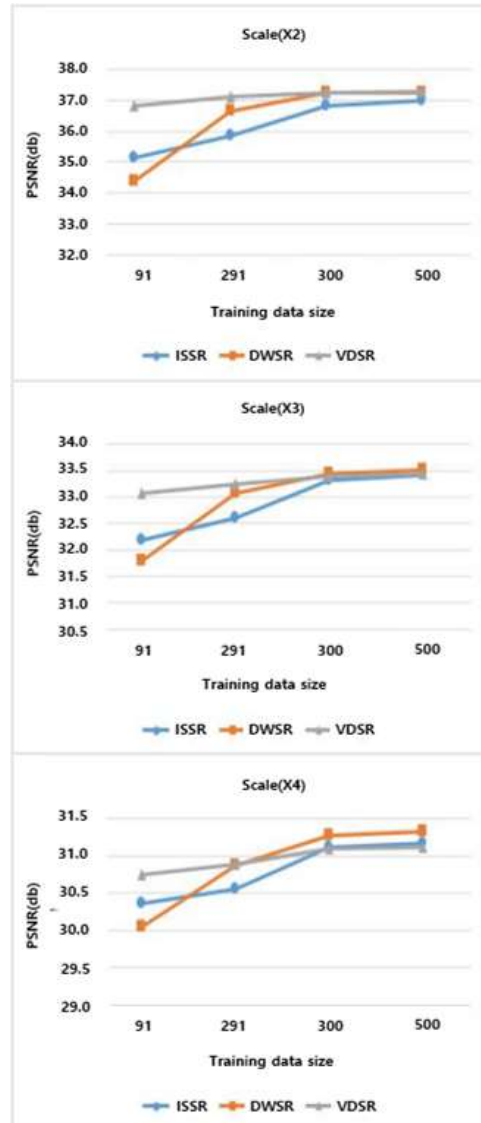


그림 8. 학습 데이터 수에 따른 스케일 ( $\times 2$ ,  $\times 3$ ,  $\times 4$ )의 성능 비교

Fig. 8 Performance comparison of scale ( $\times 2$ ,  $\times 3$ ,  $\times 4$ ) according to the number of training data

그림 6은 스케일 ( $\times 4$ )에 대한 데이터 전처리의 예다. 학습 데이터셋과 실험 데이터셋은 RGB 원본 영상인 고해상도 영상에서 YCbCr 색공간으로 변환 후, Y 성분만 추출하여 사용하게 된다. YCbCr에서는 Y 성분에 비해 CbCr이 가지는 정보를 적으므로 Y 성분을 사용한다. HR (Y) $\times 4$ 는 데이터 학습 시,






그림 9. 초해상도 복원기법의 결과

(a) 원본 이미지, (b) 고등차수 보간법, (c) VDSR, (d) DWSR, (e) ISSR

Fig. 9 Results of Super-resolution methods

(a) Original image, (b) Bicubic Interpolation, (c)VDSR, (d) DWSR, (e) ISSR

라벨 데이터로 활용되며, 학습 데이터는 HR (Y)에 고등 차수 보간법을 적용하여, 이미지 크기를 1/4만큼 줄이고 4배 확대함으로써 저해상도 영상 LR (Y)를 생성한다.

## V. 성능 분석

본 장에서는 기존의 합성곱 신경망 기반의 초해상도 복원 기법 (VDSR)과 웨이블릿 변환 기반의 초해상도 복원 기법 (DWSR, ISSR)에 대해 계층 수, 학습 데이터 수에 따른 성능에 대해 비교 분석한다.

### 1. 계층 수에 따른 성능 비교

본 실험에서는 합성곱 신경망의 계층 수를 8~22 계층에 대한 성능을 비교 분석한다. 학습 데이터셋은 NTIRE 데이터셋에서 291장을 사용했으며, 실험 데이터셋은 Set5 사용했다. 그림 7은 계층 수 변화에 따른 스케일 (×2, ×3, ×4)의 PSNR (Peak Signal-to-Noise Ratio) 성능을 측정된 것이며, 그중 VDSR은 스케일 (×2, ×3)에서 성능이 DWSR과 ISSR 보다 높다. 이는 깊은 계층을 구성하지 않고 적은 수의 계층으로 네트워크를 구성하더라도 비슷한 성능을 얻을 수 있다는 것을 의미한다. DWSR의 스케일 ×2에서는 계층 수가 성능에 영향을 미치지 않지만, 스케일 ×4의 12계층부터 20계층에서 VDSR보다 복원 성능이 높은 것을 확인할 수 있으며, ×4에서만 다른 복원기법에 비해 성능의 강점을 보인다.

### 2. 학습 데이터 수에 따른 성능 비교

본 실험에서는 계층의 개수는 동일하게 설정하

고, 학습 데이터 수에 따른 성능 변화를 분석한다. 이 실험에서는 학습 이미지로 91장, 291장, NTIRE 데이터셋 300장, 500장을 사용했으며, 실험 데이터는 Set5를 사용했다. 학습 이미지 중 91장과 291장의 평균 해상도는 400×300으로 구성되어있으며, NTIRE의 평균 해상도는 2040×1080으로 높은 해상도로 구성되어있다. 그림 8은 학습 데이터 수 (91, 291, 300, 500)에 따른 성능 변화에 따른 결과다.

VDSR의 경우 모든 스케일 (×2, ×3, ×4)에서 데이터 수 변화의 성능 차가 크지 않으며, 학습 데이터 수가 가장 작은 91장에서 DWSR과 ISSR 보다 높은 성능으로 복원한다. 하지만, ×3, ×4에서 학습 이미지 수가 300장, 500장일 때, ISSR은 VDSR 성능과 비슷해지고, DWSR은 VDSR에 비해 성능이 높은 것을 확인할 수 있다. ISSR은 학습 데이터가 91장 일 때, DWSR 보다 좋은 성능을 보이며, 학습 데이터 수에 따라 각 성능 차이가 VDSR과 DWSR 보다 큰 것을 확인할 수 있다. 이는 학습 데이터 수가 증가함에 따라 성능이 수렴하는 속도가 느린 것을 의미한다. 또한, 데이터 수 300 이상부터 DWSR 성능이 가장 높지만 학습 데이터의 수가 VDSR에 비해 많이 요구된다.

### 3. 초해상도 복원기법들의 시각적 비교

그림 9는 초해상도 기법들을 통해 복원된 결과를 나타낸 것이다. 그림 9 (c) VDSR의 복원 결과는 블러 현상과 같이 옛지가 흐릿하지만, 웨이블릿 변환을 적용한 그림 9 (d), 그림 9 (e)의 경우, 옛지 정보가 다른 복원기법 (고등차수 복원법, VDSR)에 비해 선명하게 복원되는 것을 확인할 수 있다. 또한, DWSR의 경우, ISSR 보다 고주파 영역을 복원하는데 더 나은 결과를 보여준다.

## VI. 결 론

본 논문에서는 기존의 합성곱 신경망 기반의 초해상도 복원기법인 VDSR과 웨이블릿 변환 기반의 초해상도 복원기법 (DWSR, ISSR)에 대한 분석 및 성능 비교를 했다. VDSR의 경우, 계층 수와 학습 데이터 수가 성능에 크게 영향을 끼치지 않는 것을 확인했다. 하지만 고주파 영역의 정보 손실로 인해 복원된 영상이 흐릿한 단점이 존재한다. DWSR의 경우, 학습 데이터의 수가 VDSR에 비해 많이 필요하며, 성능의 수렴속도가 늦지만 서로 다른 성분의 서브 밴드를 학습함으로써, 고주파 영역을 복원하는데 더 나은 복원 결과를 얻는다.

## References

- [1] S. Park, M. Park, M. Kang, "Super-resolution Image Reconstruction : A Technical Overview," *Journal of IEEE Transactions on Signal Processing Magazine*, Vol. 20, No. 3, pp. 21-36, 2003.
- [2] M. Irani, S. Peleg, "Improving Resolution by Image Registration," *Journal of Computer Vision Graphical Image Processing : Graphical Models and Image Processing*, Vol. 53, No. 3, pp. 231-239, 1991.
- [3] R. R. Schultz, R. L. Stevenson, "Extraction of High-resolution Frames from Video Sequences," *Journal of IEEE Transactions on Image Processing*, Vol. 5, No. 6, pp. 996-1011, 1996.
- [4] J. Yang, J. Wright, T. S. Huang, Y. Ma, "Image Super-resolution via Sparse Representation," *Journal of IEEE Transactions on Image Processing*, Vol. 19, No. 11, pp. 2861 - 2873, 2010.
- [5] Freeman W. T, Jonesm T. R, Pasztor E. C. "Example-based Super-resolution," *Journal of IEEE Transactions on Computer Graphics and Applications*, Vol. 22, No. 2, pp. 56-65, 2002.
- [6] K. Simonyan, A. Zisserman, "Very Deep Convolutional Networks for Large-scale Image Recognition," pp. 1-14, 2015.
- [7] Lim, Bee, "Enhanced Deep Residual Networks for Single Image Super-resolution," *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 136-144, 2017.
- [8] Dong, Chao, "Image Super-resolution Using Deep Convolutional Networks," *Journal of IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 38, No. 2, pp. 295-307, 2016.
- [9] J. Kim, J. Lee, K. Lee. "Accurate Image Super-resolution Using Very Deep Convolutional Networks," *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1646-1654, 2016.
- [10] Guo, Tiantong, "Deep Wavelet Prediction for Image Super-resolution," *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 104-113, 2017.
- [11] H. Lee, H.Y. Jung, G.S. Choi, "Super-Resolution Based on Convolutional Neural Network Training Wavelet Transform Data," *Proceedings of Symposium of the Korean Institute of communications and Information Sciences*, pp. 268-269, 2017 (in Korean).
- [12] O. Russakovsky, D. Jia, S. Hao, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg, F.-F. Li, "ImageNet Large Scale Visual Recognition Challenge," *International Journal of Computer Vision*, Vol. 115, No. 3, pp. 211-252, 2015.
- [13] H. D. Nguyen, "Deep Learning-based SISR (Single Image Super Resolution) Method Using RDB (Residual Dense Block) and Wavelet Prediction Network," *Korea Polytechnic University M.S thesis*, 2019.
- [14] Y. Bengio, P. Simard, P. Frasconi, "Learning Long-term Dependencies with Gradient Descent is Difficult. *Neural Networks*," *Journal of IEEE Transactions on* Vol. 5, No. 2, pp. 157 - 166, 1994.
- [15] D. Martin, C. Fowlkes, D. Tal, J. Malik, "A Database of Human Segmented Natural Images and Its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics," *Proceedings of IEEE Conference on Computer Vision*, pp. 416-423,



- 2001.
- [16] J. Yang, J. Wright, T. S. Huang, Y. Ma, "Image Superresolution via Sparse Representation," *Journal of IEEE Transactions on Image Processing*, Vol. 19, No. 11, pp. 2861-2873, 2010.
- [17] C. Bevilacqua, A. Roumy, M. Morel, "Low-complexity Single-image Super-resolution Based on Nonnegative Neighbor Embedding," *Proceedings of British Machine Vision*, pp. 1-10, 2012.
- [18] R. Zeyde, M. Elad, M. Protter, "On Single Image Scale-up Using Sparse-representations. In Curves and Surfaces," *Proceedings of International Conference on Curves and Surfaces*, pp. 711 - 730, 2012.
- [19] S. Mallat, *A Wavelet Tour of Signal Processing: the Sparse Way*, Academic press, 2008.
- [20] R. Timofte, E. Agustsson, L. Van Gool, M.-H. Yang, L. Zhang, "Ntire 2017 Challenge on Single Image Super-resolution: Methods and Results," *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 114-125, 2017.

**Hyunjae Lee (이 현 재)**



He received M.S. degree in department of information and communication engineering from Yeungnam University, Gyeongsan, Republic of

Korea, in 2018. He is currently a researcher at Erae AMS. His research interests are super resolution, computer vision, machine learning and deep learning

Email: guswo28@naver.com

**Hyunkwnag Shin (신 현 광)**



He received M.S. degree in department of information and communication engineering from Yeungnam University, Gyeongsan, Republic of

Korea, in 2017. He is currently a Ph.D. candidate in department of information and communication engineering, Yeungnam University. His research interests include text mining, computer vision, social network analysis, deep learning and databases systems.

Email: shg3786@ynu.ac.kr

**Gyu Sang Choi (최 규 상)**

He received the Ph.D. degree in Computer Science and Engineering from Pennsylvania State University. He was a research staff member at the Samsung Advanced Institute of Technology (SAIT) in Samsung Electronics from 2006 to 2009. Since 2009, he has been with Yeungnam University, where he is currently an Associate Professor. His research interests include non-volatile memory, storage systems, big data systems and supercomputing.  
Email: castchoi@ynu.ac.kr

**Seong-II Jin (진 성 일)**

He received the Ph.D. degree and M.S. in Computer Science from KAIST (Korea Advanced Institute of Science and Technology), in 1994 and 1980, respectively, and a B.S. degree in Statistics from Seoul National University. He is currently a Professor in the Department of Computer Engineering, Chungnam National University, Korea. His research interests include In-Memory DBMS, Embedded DBMS and Spatial DBMS.  
Email: sijin@cnu.ac.kr