

이미지 초해상도 향상을 위한 피드백 네트워크 연구

Study on Feedback Networks for Enhanced Image Super-Resolution

정헌석¹, 허재혁¹, 양수미^{1*}, 광성범²

¹극동대학교 에너지IT공학과, ²주식회사 위즈윙

Hunsuk Chung¹, Jaehyeok Hur¹, Sumi Yang^{1*}, Seongbeom Kwak²

¹Far East University, Department of Energy IT Engineering, Eumseong 27601, Korea

²Wizwing Co., Ltd., Incheon Metropolitan City 21990, Korea

[요약]

딥러닝 기술의 급속한 발전은 단일 이미지 초해상도(SR, super-resolution) 성능 향상에 큰 기여를 하였다. 그러나 대부분의 기존 딥러닝 기반 이미지 SR 네트워크는 정보 흐름이 순방향으로만 이루어져 성능에 한계를 보인다. 본 연구에서는 정확한 이미지 SR을 위한 피드백 네트워크를 제안한다. 이 피드백 네트워크는 여러 상위 수준의 특징을 재라우팅하여 하위 수준 특징 표현을 효과적으로 강화한다. 우리는 여러 잔차 밀도 모듈을 연속적으로 구성하고, 이를 시간에 따라 반복적으로 적용한다. 인접한 두 시간 단계 사이의 다중 피드백 연결은 충분한 문맥 정보를 가지지 못한 하위 수준 특징을 개선하기 위해, 큰 수용 필드에서 캡처된 여러 상위 수준 특징을 활용한다. 정교하게 설계된 피드백 모듈은 재라우팅된 상위 수준 특징에서 유용한 정보를 효율적으로 선택하고 이를 강화하여, 향상된 상위 수준 정보를 바탕으로 하위 수준 특징을 개선한다. 다양한 실험을 통해 제안된 방법이 객관적 및 주관적 평가에서 우수함을 입증하였다.

[Abstract]

The rapid advancement of deep learning has significantly enhanced the performance of single image super-resolution (SR). However, most existing deep learning-based image SR networks only facilitate information flow in the forward direction, which limits their performance. In this study, we investigate a feedback network for precise image SR. This feedback network effectively enhances lower-level feature representation by rerouting multiple higher-level features. We sequentially construct several Residual Density Modules and deploy them repeatedly over time. Multiple feedback connections between two adjacent time steps leverage high-level features captured within a large receptive field to refine low-level features lacking sufficient contextual information. A carefully designed feedback module efficiently selects and enhances valuable information from the rerouted high-level features, thereby improving low-level features with enriched high-level information. Extensive experiments demonstrate that the proposed method outperforms existing approaches in both objective and subjective evaluations.

Key Words: Convolutional neural network, Super-resolution, Network, Deep learning, Forward, Feedback

<http://dx.doi.org/10.14702/JPEE.2024.611>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 31 August 2024; **Revised** 16 September 2024

Accepted 24 September 2024

***Corresponding Author**

E-mail: esther4853@kdu.ac.kr

1. 서론

단일 이미지 초해상도(SR: super-resolution)는 열화된 저해상도(LR: low-resolution) 이미지로부터 고해상도(HR: high-resolution) 이미지를 복원하는 것을 목표로 한다[1-3]. 하지만 낮은 화질의 LR 이미지로부터 고화질의 HR 이미지를 얻는 것은 불가능하다. 최근 수년간 딥러닝 기반의 고화질 이미지 복원 기술은 레이어의 깊이를 깊게 하는데 치중되었는데, 예를 들어 SRCNN[4]과 RCAN[5]이 좋은 예이다. 이로부터 다양한 변형([6,7])이 나타나고 있고, 네트워크가 심화됨에 따라 필요한 매개변수가 급격히 증가하고 있다. 이 문제를 완화하기 위해 [8,9]에서는 순환 구조를 활용하였다.

그러나 거의 모든 딥러닝 기반 이미지 SR 네트워크는 전적으로 피드포워드이다. 피드포워드 방식에서는 특징이 더 얇은 레이어에서 더 깊은 레이어에 걸쳐 획득되고, 이후 최상위 레이어에서 추출된 상위 수준 기능은 초해상도 이미지를 재구성하는 데 직접 사용된다. 이러한 피드포워드 네트워크의 경우 더 얇은 레이어의 수용 필드가 더 깊은 레이어보다 작기 때문에 더 얇은 레이어는 귀중한 상황 정보의 수용을 포기하게 된다. 이를 고려할 수 없다. 이러한 단점은 이미지 재구성 능력을 저하를 초래한다.

심층 네트워크의 피드백 메커니즘은 상위 수준 피처를 얇은 레이어에 전파하여 하위 수준 피처를 개선하는 것을 목표로 한다. 상위 수준 정보의 도움으로 하위 수준 기능은 향상되고 유의미해진다. 이러한 접근법은 비전 분야([10,11])에서는 널리 활용되었지만 이미지 초해상도에는 거의 사용되지 않았다. 또한 SRFBN[12]은 이미지 SR에 대한 피드백 메커니즘의 타당성을 탐색했지만 피드백 연결은 최고 수준 기능을 얇은 레이어에만 전파하고 다양한 크기의 수용 필드에서 캡처된 다른 상위 수준 정보는 생략했다. 이러한 설계는 상위 수준 기능을 완전히 활용하지도 못하고, 하위 수준 기능을 적절하게 개선하지도 않는다.

위의 고려 사항을 기반으로 이미지 SR을 위한 피드백 네트워크를 제안한다. 가장 높은 수준의 기능은 낮은 수준의 기능을 개선하는 데 효과적일 뿐만 아니라 여러 개의 피드백 연결을 사용하여 여러 개의 높은 수준 기능을 얇은 레이어로 전송한다. 그러나 너무 높은 수준의 기능은 지나치게 중복될 수 있으며, 이를 직접 사용하면 원래의 낮은 수준의 기능과 충돌할 수 있다. 결과적으로, 우리는 낮은 수준의 기능을 개선하기 위해 유용한 상위 수준 정보를 적응적으로 선택하고 강화하는 피드백 모듈을 설계한다. 상위 수준 기능의 귀중한 상황 정보 덕분에 하위 수준 기능의 대표성이 향상되어 본질적으로 네트워크 재구성 능력이 향상된다.

본 연구의 기여는 다음과 같이 요약이 가능하다.

- 정확한 이미지 SR을 위해 피드백 네트워크를 제안한다. 광범위한 실험을 통해 제안된 연구가 다른 벤치마크보다 우수함을 입증한다.
- 하위 수준 기능을 개선하기 위해 여러 계층적 상위 수준 기능을 전파하고 여러 피드백 연결을 설계한다.
- 높은 수준의 기능은 넓은 수용 필드에서 캡처되므로 낮은 수준의 기능에는 부족한 더 많은 맥락 정보를 보유할 수 있다.
- 다중 피드백 연결을 통해 도입된 귀중한 상황 정보의 도움으로 하위 수준 기능이 더욱 대표성이 있게 되고 재구성 성능이 본질적으로 향상된다.
- 하위 수준 기능을 개선하기 위해 여러 경로가 변경된 상위 수준 기능에서 유용한 정보를 적응적으로 선택한다. 또한 추가로 성능을 향상시키기 위해 간단하면서도 효율적인 피드백 모듈을 설계한다.
- 유용한 정보만 통과하도록 허용하므로 상위 수준 기능 중 중복된 정보를 효율적으로 제거한다. 선택되고 강화된 상위 수준 정보를 통해 하위 수준 기능에 더 많은 정보를 제공할 수 있다.

II. 피드백 원리

심층 네트워크의 피드백 메커니즘은 심층 계층에서 추출된 상위 수준 정보를 얇은 계층으로 전파하여 하위 수준 기능을 더욱 대표적이고 유용하게 만드는 역할을 한다. 이는 다양한 컴퓨터 비전 작업(예: 분류[13], 포즈 추정[14])에 대해 널리 연구되었다. 이러한 네트워크에서 피드백 연결의 대부분은 단일-대-단일 방식이다. 즉, 가장 높은 수준의 기능만 가장 얇은 계층으로 전송된다. 한편, [11]은 단일-대-다중 피드백 연결을 장면 구문 분석 및 주요 객체 감지에 적용했으며, 여기서 최고 수준의 특징은 여러 얇은 레이어로 전송된다. 그들은 다른 높은 수준의 기능을 다시 제공하면 중복된 정보가 유입되고 높은 수준의 비전 작업 성능이 저하될 수 있다고 주장하였다.

우리는 이전 작업의 결함을 고려하여 정확한 이미지 SR을 위한 새로운 유형의 피드백 연결을 도입한다. 여기서 여러 계층적 상위 수준 기능이 더 얇은 레이어로 전송된다. 즉, 제안된 피드백 연결은 다중-대-단일, 다중-대-다중이다. 또한, 전파된 상위 수준 기능 중 중복 정보를 적응적으로 제거하고 선택된 상위 수준 정보를 사용하여 하위 수준 기능을 개선하도록 게이트 피드백 모듈을 설계한다. 표 1은 제안하는 피드

표 1. 제안된 피드백 네트워크 기반 초해상도 연구와 기존 CNN 기반 초해상도 연구의 차이점

Table 1. Difference between the proposed feedback network-based super-resolution study and the conventional CNN-based super-resolution study

	기존 CNN 기반 연구	제안 피드백 네트워크 기반 연구
구조	전통적인 CNN 기반 SR 모델은 일방향성 순전파 네트워크로 설계됨. 입력 이미지가 네트워크를 통과하여 고해상도 이미지로 변환되며, 이 과정은 한번 진행됨.	네트워크가 여러 번 반복적으로 이미지를 처리할 수 있는 구조를 가짐. 이를 통해 네트워크는 이전 출력을 반복적으로 참조하며 더 나은 해상도를 얻기 위해 결과를 개선함.
특징	각 층은 특정 해상도 수준에서 정보를 처리하며, 이전 단계에서 계산된 특징 맵을 바탕으로 다음 층으로 전달됨.	피드백 네트워크는 이전 출력값을 활용해 다음 예측을 정교하게 조정하며, 이 과정에서 이미지의 세부 정보를 점진적으로 복원하는 능력이 향상됨.
장단점	이미지의 세밀한 정보를 복원하는 데 제한이 있을 수 있음. 한 방향으로만 정보가 흐르기 때문에 피드백 과정이 없어 세밀한 조정이 어려움. 깊이가 깊어질수록 기울기 소실 문제가 발생함.	피드백 과정을 통해 정확한 세부 정보 복원이 가능함. 모델 학습 중 단계적으로 고해상도 이미지를 향상시키는 방향으로 작동함. 성능이 크게 향상되며 기울기 소실 문제에 대한 완화가 가능함.

백 네트워크 기반 초해상도 연구와 기존 CNN 기반 초해상도 연구의 차이점을 제시한다. 정보 처리 방식 측면에서 볼 때 기존 CNN은 단방향으로 이미지를 처리하는 반면, 피드백 네트워크는 피드백 루프를 통해 여러 번 이미지를 조정하고 개선하는 방식으로 처리한다는 장점이 있다. 또한 피드백 네트워크는 반복적으로 정보를 업데이트하여 보다 정교한 초해상도 결과를 제공하고, CNN 기반 모델에 비해 고난이도의 복잡한 패턴을 학습하고 복원하는 데 더 유리한 구조를 가진다. 이러한 피드백 네트워크는 특히 더 복잡한 이미지 처리 및 높은 수준의 세부 정보 복원이 필요한 작업에서 기존 CNN보다 더 나은 성능을 보여준다.

III. 딥러닝 기반 초해상도

최근 딥러닝 기반의 영상 SR 기술은 선구적인 연구를 통해 급속도로 발전하고 있다. 네트워크의 입력은 보간된 LR 이미지[15]에서 원본 LR 이미지[16]로 변경되었다. 이를 통해 필요한 계산 비용을 2차적으로 절감하고, 보간 연산으로 인한 모션 효과를 효율적으로 완화하였다. 또한, 다양한 스킵 연결의 적용은 네트워크가 더 깊어지고 더 나은 재구성 성능을 얻는 데 도움이 되었다. EDSR[16] 및 RCAN[5]은 잔여 건

너뛰기 연결[17]을 사용했고 SRDenseNet[18]은 조밀한 건너뛰기 연결[19]을 적용했으며 RDN[20]은 잔여 및 조밀한 건너뛰기 연결을 함께 통합했다. 그러나 이러한 네트워크에는 엄청난 양의 매개변수가 필요하다.

SRFBN[12]은 얇은 계층에 최고 수준의 기능을 제공하는 단일 대 단일 피드백 연결을 갖춘 RNN을 설계하여 이미지 SR에 대한 피드백 메커니즘의 타당성을 탐색했다. 우리는 SRFBN이 대규모 수용 필드에서 캡처된 다른 상위 수준 기능을 완전히 사용하지 못하여 하위 수준 기능을 효율적으로 개선할 수 없다고 주장한다. 대조적으로, 우리는 피드백 연결을 반복적으로 사용하여 하위 수준 기능의 표현을 풍부하게 하기 위해 여러 상위 수준 기능을 사용하도록 피드백 네트워크를 제안한다. 제안된 방법은 다수의 피드백 정보 흐름을 제외하고 앞서 언급한 RNN 기반 방법과 비교하여 세 가지 주요 차이점을 갖는다.

높은 수준의 정보에서 얻은 가치 있는 상황별 지식을 통해 낮은 수준의 기능이 더욱 유익하고 대표성을 갖게 되므로 재구성 성능이 본질적으로 향상된다. 실험 결과는 우리의 게이트 다중 피드백 연결이 단일-대-단일 및 단일-대-다중 피드백 연결보다 분명히 성능이 우수하다는 것을 보여준다. 그림 1은 딥러닝 기반 초해상도 영상의 생성 과정을 도시한다.




그림 1. 딥러닝 기반 초해상도의 예

Fig. 1. An example of deep learning based super-resolution.

IV. 제안하는 피드백 네트워크

앞서 [12,13]에서 언급했듯이 피드백 시스템의 핵심 장점은 반복적인 방식으로 출력을 입력으로 전파하는 것이다. 이 공식에 따라 우리가 제안한 피드백 네트워크는 T 시간 단계를 펼치는 컨볼루션 반복 신경망으로 자연스럽게 설계되었으며, 각 시간 단계의 하위 네트워크는 원본 LR 이미지를 사용하여 SR 이미지를 재구성하는 것을 목표로 하는 독립적인 컨볼루션 신경망으로 간주될 수 있다. 각 하위 네트워크는 주로 초기 하위 수준 특징 추출 모듈, 다중 잔차 밀도 모듈, 피드백 모듈 및 복구 모듈의 네 부분으로 구성된다. 이 네 부분의 매개변수는 시간에 따라 공유되는데, 두 개의 인접한 시간 단계에서 하위 네트워크 간의 통신은 여러 그룹의 피드백 연결을 통해 달성된다. 하나의 하단 잔차 밀도 모듈이 피드백 연결로부터 하나의 그룹을 수신하기 전에 피드백 모듈은 선택된 상위 수준 정보를 사용하여 하위 수준 기능을 더욱 개선한다. 피드백 네트워크에서는 상위 수준 특징과 하위 수준 특징이 서로 영향을 미친다. 상위 수준 특징은 하위 수준 특징의 해석을 돕고, 하위 수준 특징은 상위 수준의 추상적 의미를 구체화하는 데 도움을 준다. 상위 수준 특징에서 피드백을 통해 하위 수준 특징을 보완하거나, 하위 수준 특징을 통해 상위 수준 특징의 세밀한 디테일을 조정하는 반복적인 과정이 성능 향상에 기여한다. 일반적으로 하위 수준 특징은 기본적인 물리적인 패턴(에지, 텍스처 등)을 포착하며, 주로 이미지의 작은 디테일을 처리한다. 반면 상위 수준 특징은 추상적이고 의미 있는 정보(객체 인식, 의미적 관계)를 포착하며, 이미지의 전체적인 해석을 돕는 역할을 한다.

t 번째 시간 단계에서 피드백 네트워크의 입력 이미지로 I_{LR} 이 주어지면 두 개의 컨볼루션 레이어를 적용하여 초기 하위 수준 특징 θ 를 추출한다. 첫 번째 레이어와 두 번째 레이어는 각각 5×5 및 3×3 크기의 컨볼루션 커널을 보유하는데, θ 는 다음과 같이 구할 수 있다.

$$\theta = \Gamma_1(I_{LR}) \tag{1}$$

여기서 $\Gamma_1(\cdot)$ 는 초기 하위 수준 기능 추출 블록의 기능을 나타낸다. 그런 다음 추출된 초기 하위 수준 기능 θ 는 계층적 기능을 학습하기 위해 여러 잔차 밀도 모듈에 제공된다.

더 많은 잔차 밀도 모듈을 스택킹하면 하위 네트워크의 수용 필드 크기가 더 다양해지며 추출된 기능의 계층 구조가 더 좋아진다. 이러한 풍부한 계층적 기능은 하위 수준 기능을 개선하는 데 더 도움이 된다. 각 구체화 프로세스는 하나의 그룹이 피드백 연결을 제공하는 하나의 잔차 밀도 모듈

앞에 배치된 피드백 모듈에 의해 수행된다.

$$\theta_B = \Gamma_2(\theta) \tag{2}$$

여기서 $\Gamma_2(\cdot)$ 는 잔차 밀도 모듈과 피드백 모듈의 동작을 결합한 함수를 나타낸다. 특히, 이전 시간 단계에서 제공되는 상위 수준 정보가 부족하기 때문에 첫 번째 단계에서는 잔차 밀도 모듈 앞에 피드백 모듈이 배치되지 않는다. RDN[20]에서 사용한 전례에 따라 본 연구에서는 잔차 밀도 모듈 당 컨볼루션 레이어 수를 16으로 설정하였다. 재구성 블록에서 추출된 상위 수준 기능 θ_B 는 먼저 컨볼루션 레이어 한 개로 업스케일링된다. 그런 다음 5×5 크기의 컨볼루션 레이어는 업스케일링 기능을 사용하여 잔차 이미지를 복구한다. 마지막으로, 복구된 잔여 이미지는 보간된 LR 이미지와 결합되어 t 번째 시간 간격에서 HR 이미지 I_{HR} 을 재구성한다.

$$I_{HR} = \Gamma_2(\theta_B, I_{LR}) \tag{3}$$

제안된 피드백 네트워크에서 전개된 T 시간 단계를 통해 T 개의 고해상도 이미지를 얻을 수 있다. 마찬가지로, 각 서버 네트워크의 재구성 대상으로는 T 개의 HR 이미지가 있다. 피드백 네트워크를 최적화하기 위해 L_1 손실 기능을 채택하면 손실 함수는 다음과 같이 공식화될 수 있다.

$$L(\Psi) = \frac{1}{T} \sum_{t=1}^T \| I_{SR} - I_{HR} \|_1 \tag{4}$$

여기서 Ψ 는 제안하는 피드백 네트워크의 매개변수 세트를 나타내고, I_{HR} 은 t 번째 시간 간격의 목표 HR 이미지를 나타낸다.

피드백 모듈은 이전 시간 단계에서 다시 라우팅된 여러 상위 수준 기능을 활용하여 얇은 레이어에서 추출된 하위 수준 기능을 개선하는 데 사용된다. 하나의 피드백 모듈은 게이트 유닛과 정제 유닛으로 구성된다. 게이트 장치는 여러 상위 수준 기능에서 유용한 상위 수준 정보를 적응적으로 선택하고 향상시킨다. 정제 유닛은 먼저 선택된 의미 있는 상위 수준 정보를 사용하여 하위 수준 기능을 개선하고 다음 잔차 밀도 모듈에 정제된 하위 수준 기능을 보낸다. 피드백 모듈의 배치는 정제할 기능의 수준에 따라 결정된다. 여러 계단식 잔차 밀도 모듈 간의 상대적인 계층 관계에 따라, 우리는 하위 수준 기능을 세분화해야 한다. 따라서 여러 얇은 잔차 밀도 모듈의 입력을 선택하고, 다시 라우팅할 상위 수준 기능으로 여러 깊은 잔차 밀도 모듈의 출력을 선택한다. 가장

깊은 잔차 밀도 모듈은 특히 초기 하위 수준 기능의 개선 프로세스를 용이하게 하는 LR 공간에서 가장 대표적인 정보를 추출할 수 있으므로, 우리는 가장 깊은 잔차 밀도 모듈에서 가장 얇은 잔차 밀도 모듈까지 여러 상위 수준 기능을 제공하기 위해 피드백 연결의 여러 그룹을 사용한다. 피드백 연결의 각 그룹은 하나의 피드백 모듈에 의해 처리된다. $S = 1, 2, \dots, M - 1, M$ 을 입력이 하위 수준 기능으로 간주되는 가장 얇은 M 잔차 밀도 모듈의 선택된 인덱스 집합으로 표시하고 $D = N, N + 1, \dots, B - 1, B$ 는 출력이 이러한 하위 수준 기능을 개선하는 데 사용되는 가장 깊은 $B - M + 1$ 잔차 밀도 모듈의 선택된 인덱스 세트이다.

우리는 펼쳐진 시간 단계를 $T = 3$ 로 설정하고 각 시간 단계에서 하위 네트워크의 계단식 $B = 7$ 잔차 밀도 모듈을 설정했다. 이전 연구[21]에 따라 각 잔차 밀도 모듈의 잔여 스케일 팩터는 0.25로 설정되었다. 서브네트워크의 첫 번째 레이어와 마지막 레이어의 컨볼루션 알커널 수는 각각 C_0 및 C 로 설정된다. 다른 레이어의 컨볼루션 알커널 수는 C 로 설정된다. 제안된 피드백 네트워크에서는 각 잔차 밀도 모듈의 마지막 컨볼루션 계층과 재구성 블록을 제외한 모든 컨볼루션 및 디컨볼루션 계층 뒤에 PReLU[17] 활성화 함수가 온다. 재구성 블록에서는 이중선형 커널을 사용하여 LR 이미지를 보간한다. 다양한 업스케일 요소의 경우 역합성곱 계층의 설정은 [22]와 동일하다.

V. 실험 결과

A. 환경 설정

데이터 세트 및 평가 지표 관련하여, 우리는 훈련을 위해 DIV2K의 600개 이미지를 사용하고 크기 조정, 회전 및 뒤집기를 통해 훈련 이미지를 강화하였다. 테스트를 위해 Set5 [23], Set14[24], B100[25], Urban100[26] 및 MANGA109[27]의 5가지 표준 벤치마크 데이터세트를 사용하였다. 딥러닝 모델이 특정 데이터셋에 의존한 결과를 낸다면, 그 모델의 일반화 가능성은 제한적일 수 있다. 모델이 실제 응용에서 잘 작동하려면 다양한 환경에서 성능을 평가하고, 편향을 줄이기 위한 조치를 취해야 한다. 모델이 훈련 데이터에 과적합되지 않도록 설계하고, 검증과 교차 검증을 통해 다양한 데이터에서의 성능을 지속적으로 평가하는 것이 중요하다. 본 논문에서 채택한 Set5[23], Set14[24], B100[25], Urban100 [26] 및 MANGA109[27]의 5가지 표준 벤치마크 데이터세트는 많은 논문에서 사용하고 있는 데이터세트로서 일반화 가

능성이 충분하다고 할 수 있다.

매트랩의 `imresize` 명령어를 사용하여 HR 이미지에서 LR 이미지를 생성하였다. SR 결과는 주관적 화질 평가로 진행한다.

또한 훈련 설정 관련하여 각 반복마다 96×96 크기의 16개 저해상도 RGB 패치가 네트워크에 공급되었다. 매개변수는 He의 방법[22]을 사용하여 초기화하였다. Adam [28]은 2×10^{-4} 의 초기 학습률로 매개변수를 최적화하는 데 사용되었다. 또한 2×10^5 반복마다 학습률이 절반으로 줄어들도록 훈련하였다. 이 모델은 Pytorch 프레임워크에서 구현되었으며 NVIDIA GeForce RTX 3080 GPU에서 수행되었다.

B. 환경 설정

다음 실험에서는 첫 번째 레이어와 다른 레이어의 컨볼루션 커널 C_0 와 C 의 수가 각각 128과 32로 설정된다. 각 모델은 2×10^5 반복으로 훈련되었으며 축척 계수 $\times 5$ 를 사용하여 Urban100 데이터 세트에서 평가되었다.

다중 대 단일 피드백 연결에 대한 연구 측면에서 볼 때, 다중-단일 피드백 연결은 여러 개의 고급 기능을 첫 번째 잔차 밀도 모듈로 전송하는 것을 목표로 한다. 선택된 인덱스 세트에서 각각 $M = 1$ 및 $N = 9, 8, 7, \dots, 1$ 로 설정하여 다중-단일 피드백 방식의 9가지 사례를 비교한다. 이들 경우 중 $N = 9$ 인 경우 피드백 연결은 SRFBN[12]과 같이 단일 대 단일이다. 더 나은 비교를 위해 우리는 단일 대 다중 피드백 방식[11]을 기준으로 사용한다. 전파되는 상위 정보가 많아질수록 네트워크 성능은 점차 향상되는데 이는 여러 상위 수준 기능이 하위 수준 기능을 개선하는 데 유용하다는 것을 보여준다. 그러나 높은 수준의 기능을 과도하게 도입하면 원래 허용 수준 기능과 충돌할 수 있으므로 피크 이후 더 높은 수준의 기능을 전파하면 네트워크 재구성 성능이 저하된다.

다중 대 다중 피드백 연결에 대한 연구 측면에서 볼 때, 다중 대 다중 방식의 요구 사항을 충족하기 위해 $N = 5$ 를 $N = 1, 2, 3, \dots, 9$ 로 고정한다. 이 경우 더 얇은 잔차 밀도 모듈이 높은 수준의 정보를 수신할수록 성능이 점차 저하되는 것을 보여준다. 이는 첫 번째 잔차 밀도 모듈이 이미 재라우팅된 상위 수준 기능의 정보를 완전히 활용했기 때문이다. 상위 수준 기능이 다른 잔차 밀도 모듈로 전파되면 새로 개선된 하위 수준 기능과 충돌하여 네트워크 재구성 기능을 방해할 수 있다. 그럼에도 불구하고 다중 대 단일 피드백 연결은 여전히 단일 대 다중 피드백 연결보다 더 나은 성능을 발휘한다. 이는 가장 높은 수준의 기능뿐만 아니라 여러 기능이 낮은 수준의 기능을 개선하는 데 도움이 된다는 것을 추가로 보여준다.

반 피드백 연결에 대한 연구 측면에서 볼 때 우리는 제안된 다중 피드백 연결의 효율성을 더 자세히 설명하기 위해 안티 피드백 연결을 설계한다. 자세하게는 피드백 연결을 역전시켜 가장 얇은 잔차 밀도 모듈에서 추출된 하위 수준 정보를 가장 깊은 잔차 밀도 모듈로 전송한다. M 과 N 의 정의와 유사하게, 우리는 M 과 N 을 사용하여 전송될 하위 수준 기능 수와 개선할 상위 수준 기능 수를 제어한다. 다중 대 단일 피드백 연결과 달리 $N = 9$ 로 설정하고 다양한 M 을 결합하여 다중-대-단일 안티 피드백 연결을 달성한다. 안티 피드백 연결은 제안된 다중 피드백 연결에 비해 더 나쁜 재구성 효과를 나타낸다. 이는 하위 수준 정보를 활용하여 상위 수준 기능을 향상시키는 것이 풍부한 상위 수준 정보를 사용하여 하위 수준 기능을 개선하는 것보다 효율성이 낮다는 것을 보여준다.

게이트 피드백 모듈에 대한 연구 측면에서 볼 때, 피드백 모듈의 정제 장치는 피드백 연결을 수신하여 인접한 두 시간 단계 간의 통신을 달성한다. 모든 피드백 모듈 또는 피드백 모듈의 모든 정제 단위를 직접 제거하면 두 시간 단계 간의

통신이 끊어진다. 따라서 우리는 피드백 모듈에서 게이트 유닛의 필요성만을 조사한다.

C. 최신기술과의 비교

이 하위 섹션에서 제안된 피드백 네트워크는 $N = 5$ 및 $M = 1$ 로 설정하여 다중 피드포워드 연결을 갖추고 있다. C_0 와 C 는 각각 256 및 64로 확장된다. 우리는 제안 방법을 SRCNN[4], VDSR[15], DRRN[29], NLRN[29], EDSR[16], D-DBPN[7]의 8가지 최신 SR 방법과 비교하여 효율성을 입증한다. 정성적 평가 결과가 그림 2와 그림 3에 제시된다. 그림에서 볼 수 있듯이 제안된 방법은 기존 방법 대비 우수한 화질을 보였다.

VI. 결론

본 논문에서는 정확한 초해상도 이미지를 얻기 위해 피드




그림 2. 제안된 방법과 다른 벤치마크들 간의 비교 (Urban100의 Img_004)

Fig. 2. Comparison between the proposal method with other benchmarks (Img_004 in Urban100).




그림 3. 제안된 방법과 다른 벤치마크들 간의 비교 (UchiNoNyansDiary)

Fig. 3. Comparison between the proposal method with other benchmarks (UchiNoNyansDiary).

백 네트워크를 제안하였다. 여러 계층적 상위 수준 기능을 얇은 레이어에 전파하여 하위 수준 기능의 표현을 성공적으로 강화한다. 정교하게 설계된 피드백 모듈은 피드백 연결을 제공하는 여러 그룹에서 의미 있는 상위 수준 정보를 효율적으로 선택 및 강화하고 선택되고 향상된 상위 수준 정보를 사용하여 하위 수준 기능을 개선한다. 다양한 피드백 방식을 조사하고 분석하는 광범위한 실험은 제안된 다중 피드백 연결의 우수성을 보여준다. 두 개의 시간 단계와 각각 7개의 잔차 밀도 모듈을 포함하는 제안된 피드백 네트워크는 기존 이미지 SR 방법에 비해 더 나은 재구성 성능을 달성한다.

감사의 글

본 논문은 2024년도 행정안전부 및 산업기술기획평가원(KEIT) 연구비 지원에 의한 연구(20025104)와, 2024년도 산업통상자원부 및 한국에너지기술평가원(KETEP) 연구비 지원에 의한 연구입(20224000000070).

참고문헌

- [1] A. Niu, K. Zhang, T. X. Pham, J. Sun, Y. Zhu, I. S. Kweon, and Y. Zhang, "CDPMSR: Conditional diffusion probabilistic models for single image super-resolution," *2023 IEEE International Conference on Image Processing (ICIP)*.
- [2] Q. Ding and J. Yang, "Sparse-aware transformer for single image super-resolution, 2023 2nd international conference on cloud computing," *Big Data Application and Software Engineering (CBASE)*, 2023.
- [3] M. Mikaeili and H. Ş. Bilge, "Evaluating deep neural network models on ultrasound single image super resolution," *2023 Medical Technologies Congress (TIPTEKNO)*.
- [4] C. Dong, C. C. Loy, K. He, and X. Tang, "Learning a deep convolutional network for image super-resolution," *In ECCV*, 2014.
- [5] Y. Zhang, K. Li, K. Li, L. Wang, B. Zhong, and Y. Fu, "Image super-resolution using very deep residual channel attention networks," *In ECCV*, 2018.
- [6] C. Dong, C. C. Loy, and X. Tang, "Accelerating the super-resolution convolutional neural network," *In ECCV*, 2016.
- [7] M. Haris, G. Shakhnarovich, and N. Ukita, "Deep back-projection networks for super-resolution," *In CVPR*, 2018.
- [8] W. Han, S. Chang, D. Liu, M. Yu, M. Witbrock, and T. S. Huang, "Image super-resolution via dual-state recurrent networks," *In CVPR*, 2018.
- [9] J. Kim, J. K. Lee, and K. M. Lee, "Deeply-recursive convolutional network for image super-resolution," *In CVPR*, 2016.
- [10] J. Carreira, P. Agrawal, K. Fragkiadaki, and J. Malik, "Human pose estimation with iterative error feedback," *In CVPR*, 2016.
- [11] X. Jin, Y. Chen, Z. Jie, J. Feng, and S. Yan, "Multi-path feedback recurrent neural networks for scene parsing," *In AAAI*, 2017.
- [12] Z. Li, J. Yang, Z. Liu, X. Yang, G. Jeon, and W. Wu, "Feedback network for image super-resolution," *In CVPR*, 2019.
- [13] A. R. Zamir, T. L. Wu, L. Sun, W. B. Shen, B. E. Shi, J. Malik, and S. Savarese, "Feedback networks," *In CVPR*, 2017.
- [14] M. Liang, X. Hu, and B. Zhang, "Convolutional neural networks with intralayer recurrent connections for scene labeling," *In NeurIPS*, 2015.
- [15] J. Kim, J. K. Lee, and K. M. Lee, "Accurate image super-resolution using very deep convolutional networks," *In CVPR*, 2016.
- [16] B. Lim, S. Son, H. Kim, S. Nah, and K. M. Lee, "Enhanced deep residual networks for single image super-resolution," *In CVPRW*, 2017.
- [17] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *In CVPR*, 2016.
- [18] T. Tong, G. Li, X. Liu, and Q. Gao, "Image super-resolution using dense skip connections," *In ICCV*, 2017.
- [19] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *In CVPR*, 2017.
- [20] Y. Zhang, Y. Tian, Y. Kong, B. Zhong, and Y. Fu, "Residual dense network for image super-resolution," *In CVPR*, 2018.
- [21] X. Wang, K. Yu, S. Wu, J. Gu, Y. Liu, C. Dong, Y. Qiao, and C. Change Loy, "Esrgan: Enhanced super-resolution generative adversarial networks," *In ECCV*, 2018.
- [22] K. He, X. Zhang, S. Ren, and J. Sun, "Delving Deep into Rectifiers: Surpassing human-level performance on imagenet classification," *In ICCV*, 2015.

- [23] M. Bevilacqua, A. Roumy, C. Guillemot, and M. L. Alberi-Morel, "Low-complexity single image super-resolution based on nonnegative neighbor embedding," *In BMVC*, 2012.
- [24] R. Zeyde, M. Elad, and M. Protter, "On single image scale-up using sparse-representations," *In Curves and Surfaces*, 2010.
- [25] D. Martin, C. Fowlkes, D. Tal, and J. Malik, "A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics," *In ICCV*, 2001.
- [26] J. B. Huang, A. Singh, and N. Ahuja, "Single image super-resolution from transformed self-exemplars," *In CVPR*, 2015.
- [27] Y. Matsui, K. Ito, Y. Aramaki, A. Fujimoto, T. Ogawa, T. Yamasaki, and K. Aizawa, "Sketch-based manga retrieval using manga109 dataset," *Multimedia Tools and Applications*, vol. 76, pp. 21811-2183, 2017.
- [28] Y. Tai, J. Yang, and X. Liu, "Image super-resolution via deep recursive residual network," *In CVPR*, 2017.
- [29] D. Liu, B. Wen, Y. Fan, C. C. Loy, and T. S. Huang, "Non-local recurrent network for image restoration," *In NeurIPS*, 2018.



정 현 석 (Hunsuk Chung)_정회원

1991년 : 서울과학기술대학교 전산학(공학사)
1993년 : 홍익대학교 데이터베이스 (이학석사)
1999년 : 홍익대학교 데이터베이스 (이학박사)
2003년 ~ 현재 : 극동대학교 에너지IT공학과 교수
관심분야 : 컴퓨터교육, 데이터베이스, 영상분석
E-mail: hschung@kdu.ac.kr



허 재 혁 (Jaehyeok Hur)_정회원

2023년 : 극동대학교 에너지IT공학과(이학사)
2023년 ~ 현재 : 극동대학교대학원 친환경에너지공학과 석사과정
관심분야 : 에너지IT, 드론영상분석, 신재생에너지
E-mail: hgh9848@naver.com



양 수 미 (Sumi Yang)_정회원

1992년 : 공주대학교 물리학과(이학사)
1999년 : 충남대학교 물리학과 고체물리전공(이학석사)
2020년 ~ 현재 : 극동대학교 에너지IT공학과 조교수
관심분야 : 에너지IT, 드론영상분석, 신재생에너지
E-mail: esther4853@kdu.ac.kr



곽 성 범 (Seongbeom Kwak)_정회원

2017년 : 인천대학교 전자공학과(공학사)
2023년 : 인천대학교 임베디드시스템전공(석사과정)
2017년 ~ 현재 : (주)위즈윙 부대표
관심분야 : 무인항공기, 임베디드시스템
E-mail: rnd@wiziwng.co.kr