

캐스케이드 융합 기반 다중 스케일 열화상 향상 기법

이경재*

Cascade Fusion-Based Multi-Scale Enhancement of Thermal Image

Kyung-Jae Lee*

요약

본 연구는 다양한 스케일 조건에서 열화상 이미지를 향상시키기 위한 새로운 캐스케이드 융합 구조를 제안한다. 특정 스케일에 맞춰 설계된 방법들은 다중 스케일에서 열화상 이미지 처리에 한계가 있었다. 이를 극복하기 위해 본 논문에서는 다중 스케일 표현을 활용하는 캐스케이드 특징 융합 기법에 기반한 통합 프레임워크를 제시한다. 서로 다른 스케일의 신뢰도 맵을 순차적으로 융합함으로써 스케일에 제약받지 않는 학습이 가능해진다. 제안된 구조는 상호 스케일 의존성을 강화하기 위해 엔드 투 엔드 방식으로 훈련된 합성곱 신경망으로 구성되어 있다. 실험 결과, 제안된 방법은 기존의 다중 스케일 열화상 이미지 향상 방법들보다 우수한 성능을 보인다는 것을 확인할 수 있었다. 또한, 실험 데이터셋에 대한 성능 분석 결과 이미지 품질 지표가 일관되게 개선되었으며, 이는 캐스케이드 융합 설계가 스케일 간 견고한 일반화를 가능하게 하고 교차 스케일 표현 학습을 더 효율적으로 수행하는 데 기여하는 것을 보여준다.

ABSTRACT

This study introduces a novel cascade fusion architecture aimed at enhancing thermal images across various scale conditions. The processing of thermal images at multiple scales has been challenging due to the limitations of existing methods that are designed for specific scales. To overcome these limitations, this paper proposes a unified framework that utilizes cascade feature fusion to effectively learn multi-scale representations. Confidence maps from different image scales are fused in a cascaded manner, enabling scale-invariant learning. The architecture comprises end-to-end trained convolutional neural networks to enhance image quality by reinforcing mutual scale dependencies. Experimental results indicate that the proposed technique outperforms existing methods in multi-scale thermal image enhancement. Performance evaluation results are provided, demonstrating consistent improvements in image quality metrics. The cascade fusion design facilitates robust generalization across scales and efficient learning of cross-scale representations.

키워드

Thermal Image, Infrared Image, Image Enhancement, Convolutional Neural Networks, Feature Fusion
열화상 이미지, 적외선 이미지, 이미지 향상, 합성곱 신경망, 특징 융합

* 교신저자 : 용인대학교 AI학부

• 접수일 : 2023. 12. 06

• 수정완료일 : 2024. 01. 09

• 게재확정일 : 2024. 02. 17

• Received : Dec. 06, 2023, Revised : Jan. 09, 2024, Accepted : Feb. 17, 2024

• Corresponding Author : Kyung-Jae Lee

School of Artificial Intelligence, Yong In University,

Email : kilee@yongin.ac.kr

• 이 논문은 2020년 용인대학교 학술연구조성비 재원으로 수행된 연구임

I. 서 론

적외선 이미지는 어두운 조명 환경에서도 강력한 성능을 발휘하며[1, 2], 물체의 열 정보를 담고 있다는 장점이 있어, 감시 시스템[3], 얼굴 인식 및 추적, 고급 운전자 보조 시스템 등 광범위한 응용 분야[4]에서 고화질 열화상 이미지 획득을 위한 연구가 활발히 진행되고 있다. 열화상 이미지는 시각 센서의 한계를 극복하는 데 중요한 역할을 하고 있으며, 이러한 열화상 이미지의 품질을 향상시키기 위한 다양한 접근 방법들이 제안되었다.

기존의 연구들은 대부분 열화상의 저화질을 개선하기 위해 이미지 처리 기법을 활용하여 잡음을 감소시키고 대비를 강화하는 등의 방법[5]으로 화질을 향상시키는 것에 초점을 맞추었다.

열화상 이미지 향상을 위한 한 연구[6]에서, 저자는 컨볼루션 신경망 기반의 초해상도 접근 방법을 제안했다. 회색조 이미지와 적외선 이미지를 혼련 데이터로 사용하는 신경망 네트워크 간 비교를 통해, 회색조 이미지를 사용하는 네트워크가 적외선 이미지를 사용하는 것보다 더 우수한 성능을 보인다는 것을 발견했다. 또한, 열화상의 품질이 향상됨에 따라, 이를 활용한 응용 프로그램의 성능 향상으로 이어진다는 것을 검증했다. 이 연구는 열화상의 질적 개선이 단순한 이미지 처리를 넘어서 응용 분야에서의 실질적인 성능 향상에 기여할 수 있다는 것을 시사한다. 이러한 발견은 열화상 기술의 발전이 다양한 분야에서 의미 있는 영향을 미칠 수 있다는 점을 강조하며, 특히 초해상도 기술이 실용적인 응용 프로그램에서 중요한 역할을 할 수 있다는 것을 보여준다.

열화상 개선을 위한 잔차 네트워크[7]를 제시한 기법[8]에서는 열화상 개선을 위한 네트워크 훈련 도메인으로 밝기(Brightness) 영역이 가장 적합하다는 사실을 검증하였다. 이 방법은 저품질 입력 열화상과 잔차 출력 이미지를 요소별로 합산하여 고품질의 열화상 이미지를 출력한다. 이 연구는 열화상 처리 분야에서 네트워크 학습에 있어서 밝기 도메인의 중요성을 부각하며, 잔차 학습이 열화상의 세부 사항을 보존하면서 전체적인 화질을 향상시킬 수 있는 유망한 방법임을 시사한다. 이러한 접근 방식은 저품질의 원본 이미지에 부족한 세부 정보를 보완하여, 최종적으로 더

욱 명확하고 선명한 시각 정보를 제공하는 데 기여할 수 있다.

하지만 이러한 방법들은 대체로 단일 스케일의 이미지에 초점을 맞추거나 특정 조건에 최적화되어 있어, 다양한 스케일과 조건에서 발생하는 열화상의 특성을 포괄적으로 다루기에는 한계가 있다. 이에 따라, 다양한 환경에서 얻어진 열화상들의 품질을 일관되게 향상시킬 수 있는 새로운 접근 방법이 필요하다.

이러한 한계를 극복하기 위하여, 열화상 이미지의 다양한 크기에 유연하게 대응할 수 있는 멀티스케일 앙상블 학습 기법[9]이 개발되었다. 저자들은 여러 수준의 신뢰도 맵을 활용하는 병렬 구조의 네트워크를 설계하고, 이를 통해 다양한 스케일의 이미지를 처리할 수 있는 모델을 구성하였다.

본 논문에서는 단일 스케일 모델 구조의 학습 방법을 극복하고, 다양한 스케일의 이미지를 단일 모델로 처리하면서 열화상의 품질을 향상시키는 네트워크를 제안한다. 스케일에 따른 특징을 보존하면서 정교한 특징 추출이 가능한 캐스케이드 융합 구조 기반의 딥러닝 모델을 설계하였다. 다양한 실험을 통해 1) 캐스케이드 구조에 의한 특징 융합 방식, 2) 입력 이미지와 최종 출력 이미지 사이의 잔차 구조, 3) 이전 단계와 현재 단계의 특징 사이의 잔차 구조를 적용한 모델이 다중 스케일 품질에 미치는 영향을 분석하였다.

II. 딥러닝 네트워크 기본 모듈

본 장에서는 다중 스케일 열화상 향상을 위한 기본 네트워크 모듈을 소개한다. 본 논문의 캐스케이드 구조를 이루는 딥러닝 모델의 기본 네트워크 구조는 특징 추출 모듈, 맵핑 모듈, 재건 모듈로 이루어져 있으며, 각 모듈은 밝기 도메인 잔차 딥러닝 모델[8]과 앙상블 딥러닝 학습 모델[9]에서 사용된 모듈 구조를 이용하였다.

그림 1에와 같이 특징 추출 모듈은 입력 맵으로부터 특징 맵을 추출하며, 각 레이어는 3×3 커널 크기의 컨볼루션과 PReLU로 구성되어 있고, 총 세 개의 레이어가 연속된다. 첫 번째 레이어는 딥러닝 모델의 시작 단계에서 단일 채널의 열화상 이미지를 입력으로 받아 활용하며, 그 이후 단계에서는 이전 단계의




그림 1. 네트워크 기본 모듈
Fig. 1 Basic modules of the network

맵핑 모듈로부터 48개의 출력 특징 맵을 입력으로 받는다. 이러한 입력으로부터 48개의 출력 특징 맵 채널을 생성하고, 이어지는 두 레이어는 이전 레이어로부터 48개의 특징 맵 채널을 받아, 48 채널 크기의 출력 특징 맵을 추출하는 방식으로 학습된다.

이 모듈은 입력으로부터 다양한 수준의 특징들을 효과적으로 포착하기 위해 고안되었고, 이러한 구조적 접근은 딥러닝 모델에게 이미지의 세밀한 정보를 정밀하게 추출하는 능력을 부여하며, 이를 바탕으로 더욱 정교한 이미지 분석을 수행할 수 있도록 한다. 또한, 다층적 특징 추출 과정은 모델이 더욱 풍부한 정보를 담은 특징 맵을 생성하도록 하여, 최종적인 이미지 처리 결과의 품질을 향상시키는 역할을 한다.

표 1. 특징 추출 모듈
Table 1. Feature Extraction Module

Stage	Layer	Input Dimension	Output Dimension
First	Conv(3X3)-PReLU	1	48
	Conv(3X3)-PReLU	48	48
	Conv(3X3)-PReLU	48	48
Subsequent	Conv(3X3)-PReLU	48	48
	Conv(3X3)-PReLU	48	48
	Conv(3X3)-PReLU	48	48

표 1에서와 같이 맵핑 모듈은 특징 추출 모듈로부터 얻은 특징 맵을 비선형적으로 매핑하는 역할을 하며, 이때 활성화 함수로는 PReLU가 사용된다. 첫 번째 레이어인 축소 레이어와 마지막 레이어인 확장 레이어는 각각 1×1 커널을 가진 컨볼루션 레이어를 통해 특징 맵의 채널 수를 줄이고 늘린다. 이 레이어들을 통해 맵핑 모듈을 깊게 구축할 수 있게 하며, 이를 통해 비선형성을 증가시킬 수 있다. 중간에 위치한 다섯 개의 레이어는 3×3 커널 크기의 컨볼루션 레

이어로, 비선형 매핑을 위한 16개의 채널을 가진 특징 맵을 가지고 있다. 이 모듈은 고차원의 특징 맵을 효과적으로 압축하고 확장함으로써, 더 복잡한 비선형 관계를 모델링할 수 있는 능력을 향상시키는 역할을 한다. 축소와 확장 과정은 데이터의 중요한 특성을 보존하면서 차원을 조절하여, 계산 효율성과 처리 속도를 개선하는 동시에, 중간 레이어들은 깊은 네트워크 내에서 세밀한 특징들의 비선형 매핑을 담당한다. PReLU 활성화 함수를 적용함으로써, 이러한 비선형 매핑 과정에서 모델의 학습 능력을 강화시켜, 최종적으로 더 정밀하고 섬세한 이미지 재구성을 가능하게 한다.

표 2. 맵핑 모듈
Table 2. Mapping Module

Layer	Input Dimension	Output Dimension
Conv(1X1)-PReLU	48	16
Conv(3X3)-PReLU	16	16
Conv(3X3)-PReLU	16	16
Conv(3X3)-PReLU	16	16
Conv(3X3)-PReLU	16	16
Conv(3X3)-PReLU	16	16
Conv(3X3)-PReLU	16	16
Conv(1X1)-PReLU	16	48

표2, 3과 같이 재건 모듈은 각 단계의 맵핑 모듈 뒤에 위치하여 단계별 특징 맵을 취합한 뒤 고품질 이미지 재건을 위한 잔차 이미지와 해당 이미지의 신뢰도를 생성한다. 이 모듈은 네트워크가 중요한 이미지 정보를 복원하는 동시에 각 픽셀의 정확도를 평가할 수 있도록 설계되었다. 잔차 이미지는 원본 이미지에서 누락된 세부 사항을 보완하는 반면, 픽셀 신뢰도는 예측된 픽셀값의 정확성을 의미한다.

표 3. 재건 모듈
Table 3. Reconstruction Module

Layer	Input Dimension	Output Dimension
Conv(3X3)	48	2

재건 모듈의 위치는 네트워크가 여러 단계에서 얻은 특징 정보를 종합적으로 활용할 수 있게 하여, 최종 출력의 정밀도를 높이는 역할을 한다. 활성화 함수 없이 컨볼루션 레이어를 이용하여 정보의 직접적인 재구성을 가능하게 한다.

III. 캐스케이드 융합 네트워크 구조

본 장에서는 다중 스케일 열화상 향상을 위해 제안한 캐스케이드 융합 네트워크의 최적 설계를 결정하기 위한 실험 및 분석 내용에 대해 다룬다.

3.1 캐스케이드 융합 구조 분석

2장에서 소개한 기본 구조를 기반으로, 그림 2에서와 같이 캐스케이드 융합 구조의 효과를 분석하기 위해 우선 2개의 단계 구조를 기본으로 설정하였다.




그림 2. 캐스케이드 2단계 기본 융합 구조
Fig. 2 Two-Stage Cascaded Fusion Structure

융합 방법으로는 1) 입력 열화상 이미지를 잔차 학습 기법으로 처리하는 것, 2) 두 번째 단계에서 첫 번째 단계의 출력 특징 맵에 잔차 학습을 적용하는 것, 3) 첫 번째 단계의 출력 열화상 이미지를 두 번째 단계의 출력 열화상 이미지와 잔차 학습을 통해 처리하는 것을 조합하여 다양한 융합 구조에 대해 총 6개의 캐스케이드 융합 구조를 설계하였다.

그림 3에서 볼 수 있듯이, 모델 A의 융합 구조는 기본적인 융합 구조에 기반을 두고 있으며, 입력 열화상 이미지를 최종 열화상 이미지가 출력되기 바로 전에 추가함으로써 잔차 학습을 가능하게 하도록 설계되었다. 이러한 접근 방식은 모델이 입력 데이터의 원본 특성을 유지하면서도, 출력 이미지에서 필요한 변경 사항만을 학습하여 더해주는 방식으로 열화상 이미지의 품질을 향상시킬 수 있다.




그림 3. 캐스케이드 융합 구조 모델 A
Fig. 3 Cascade Fusion Structure Model A




그림 4. 캐스케이드 융합 구조 모델 B
Fig. 4 Cascade Fusion Structure Model B

모델 B의 융합 구조(그림 4)는 첫 번째 단계와 두 번째 단계에서 생성된 열화상 이미지들을 각각의 신뢰도 맵과 결합한 후 더해진 결과물에 원본 입력 열화상 이미지를 추가함으로써 잔차 학습을 적용하는 방식으로 설계되었다. 모델 A와의 주요 차이점은, 모델 A에서는 캐스케이드 구조를 통해 합산된 결과 이미지에만 잔차 학습이 적용되었던 반면, 모델 B에서는 각 단계의 출력 이미지가 결합되기 바로 전에 원본 입력 열화상 이미지에 잔차 학습을 적용하여, 각 단계에서의 정보를 보다 효과적으로 활용하도록 설계하였다.




그림 5. 캐스케이드 융합 구조 모델 C
Fig. 5 Cascade Fusion Structure Model C

모델 C 융합 구조(그림 5)는 입력 열화상 이미지를 최종 열화상 이미지가 출력되는 바로 전 단계에 추가함으로써 잔차 학습이 적용되도록 설계되었으며, 이와 함께 두 번째 입력으로 제공되는 첫 번째 단계의 특징 맵에 대해서도 잔차 학습을 수행하는 방식을 도입했다. 이러한 구조는 네트워크가 초기 입력 이미지와 중간 단계의 특징 정보 모두를 활용하여 더욱 정밀한 열화상 이미지 복원을 달성할 수 있도록 설계하였다.




그림 6. 캐스케이드 융합 구조 모델 D
Fig. 6 Cascade Fusion Structure Model D

그림 6에서 보이는 바와 같이, 모델 D는 모델 B의 잔차 학습 방식과 모델 C의 특징 맵에 적용된 잔차 학습 방식을 결합한 구조로 설계되었다. 이 구조는 두 모델에서 적용된 기법을 통합하여, 입력 열화상 이미지의 세부 정보를 더욱 정밀하게 복원하고, 중간 단계에서 추출된 특징 맵의 정보를 더욱 효과적으로 활용할 수 있도록 설계되었다.




그림 7. 캐스케이드 융합 구조 모델 E
Fig. 7 Cascade Fusion Structure Model E




그림 8. 캐스케이드 융합 구조 모델 F
Fig. 8 Cascade Fusion Structure Model F

모델 E(그림 7)와 모델 F(그림 8)는 첫 번째 단계에서 잔차 학습을 통해 얻은 출력 이미지를 두 번째 단계에서의 잔차 학습에 활용하는 방식이다. 이러한 구조는 첫 번째 단계의 학습 결과를 두 번째 단계의

학습 과정에 통합함으로써, 각 단계의 출력이 서로 보완적인 정보를 제공하고, 전체적인 이미지 복원의 정확도를 높이는 데 기여할 수 있도록 설계하였다.

캐스케이드 융합 구조를 설정하기 위하여 위와 같이 총 6개의 구조를 설계하였고, 이어지는 4장의 실험 방법과 동일하게 실험을 구성하여 성능을 비교하였다.

표 4. 캐스케이드 융합 구조 모델 실험 결과
Table 4. Performance of Cascade Fusion Model

Model	PSNR		
	X2	X3	X4
A	39.411	36.125	33.819
B	39.396	36.137	33.835
C	39.434	36.213	33.864
D	39.412	36.178	33.859
E	39.434	36.154	33.846
F	39.427	36.160	33.870

표 4에 나타난 실험 결과를 분석해본 결과, 모델 C의 구조, 즉 입력 열화상 이미지에 대한 잔차 학습과 이전 단계의 특징 맵을 이용하여 다음 단계에서 잔차 학습을 진행하는 방식이 이미지 품질 향상에 매우 효과적임을 알 수 있다. 이는 네트워크가 초기 입력 이미지와 중간 단계에서 추출된 특징 정보를 활용함으로써 성능 개선에 도움이 된다는 것을 입증하며, 특징 맵 잔차 학습이 적용된 모델 C, D, F가 전반적으로 우수한 성능을 보인다. 이러한 결과는 입력된 열화상 이미지뿐만 아니라 특징 맵의 적절한 잔차 학습의 효과성에 대해서 검증할 수 있었다.

3.2 캐스케이드 단계 분석

최적의 모델을 선정하기 위해, 3.1절에서 검증된 캐스케이드 융합 구조를 갖는 모델 C를 기준으로 하여, 단계별로 확장하며 성능을 비교하는 실험을 진행하였다. 본 논문의 모든 실험은 동일한 환경에서 수행되었으며, 전이 학습 없이 2단계에서부터 6단계까지 점진적으로 단계를 추가하며 각각의 성능을 평가했다.

단계별 성능 평가를 진행한 결과, 네 개의 연속적인 단계를 가진 캐스케이드 융합 구조가 전반적으로 우수한 성능을 나타냈다. 스케일 3에서는 5단계 구조가 미세하게 0.005만큼 더 우수한 성능을 보였지만,

스케일 2와 4에서는 4단계 구조가 전체적으로 더 우수한 성능을 보였다. 또한, 모델의 구조가 더 단순하다는 점을 고려했을 때, 4단계로 구성된 캐스케이드 융합 구조가 가장 적합한 모델로 판단된다. 표 5와 같이 이러한 분석을 통해 모델의 단계별 성능 변화를 상세히 조사할 수 있었으며, 이는 최종 모델을 결정하는 데 중요한 기준이 되었다.

표 5. 캐스케이드 융합 단계별 실험 결과
Table 5. Performance of Cascade Fusion Level

Stage	PSNR		
	X2	X3	X4
2	39.434	36.213	33.864
3	39.504	36.261	33.872
4	39.622	36.326	33.972
5	39.603	36.331	33.935
6	39.601	36.370	33.971

IV. 실험 결과 및 분석

4.1 실험 환경

MSEL[9]에서 사용된 방법과 동일한 실험 환경에서 성능 측정을 수행하였다. 91 이미지 데이터셋[10]을 훈련용으로 사용하였으며, 총 30장의 고화질 열화상 이미지[11, 12]를 테스트 데이터셋으로 활용하였다. 훈련 과정에서 훈련 이미지들은 밝기(Brightness) 도메인으로 변환되었으며, 이미지 패치 크기는 중첩을 고려하여 48×48 로 설정되었고, 스트라이드는 24로 설정하였다. 또한, 훈련 데이터는 90, 180, 270도 회전 및 수직 뒤집기를 기반으로 증강되었다. 총 55,040개의 패치가 훈련에 사용되었다. 학습률은 50 에포크까지 $1e-3$ 으로 초기화하였다. 테스트용 입력 이미지는 기준 이미지를 다운샘플링 한 뒤, 바이 큐빅 보간법을 사용하여 원래 크기로 업샘플링 하여 $\times 2$, $\times 3$, $\times 4$ 의 스케일 팩터로 생성되었다.

4.2 성능 실험

비교 실험을 수행하여 제안된 네트워크의 성능을 기존의 다른 방법들과 비교 분석하였다. 바이 큐빅 방법과 열화상 이미지 향상 기법인 TEN[6], TIECNN[8],

ASR2_s[13], MSEL[9]과 비교하였다. 평가는 테스트 데이터셋을 사용하여 진행되었으며, 기준 진리(Ground-truth)에 대한 피크 신호 대 잡음 비율(PSNR)을 평가 지표로 사용하였다. 표 6에서와같이, 제안된 구조가 모든 스케일에서 우수한 성능을 보이는 것을 확인하였다.

표 6. 비교 실험 결과

Table 6. The results of the comparative experiments

Methods	PSNR		
	X2	X3	X4
Bicubic	36.972	33.899	31.860
TEN (X2)	37.378	34.143	31.932
TEN (X3)	36.065	34.350	32.191
TEN (X4)	34.602	33.694	32.114
TIECNN (X2)	39.196	34.053	31.846
TIECNN (X3)	34.216	35.752	32.391
TIECNN (X4)	31.352	33.379	33.258
ASR2_s	38.348	34.978	32.969
MSEL	39.325	36.055	33.735
Proposed	39.622	36.326	33.972

V. 결론

본 연구는 스케일 변동에 강건한 열화상 이미지의 질적 향상을 위해, 다중 스케일 특성을 적용할 수 있는 캐스케이드 특징 융합 방식을 기반으로 한 단일 네트워크를 제안하였다. 서로 다른 스케일의 특성을 차례대로 융합함으로써, 스케일 제한 없이 학습이 가능하도록 하였고, 이를 구현하기 위해 다양한 융합 구조를 설계하고 연구하여, 최적화된 성능을 발휘하는 네트워크 구조를 도출하였다. 실험 결과, 제안된 방식은 기존의 다양한 열화상 이미지 향상 기법들에 비해 뛰어난 성능을 보인다는 것을 확인하였다.

감사의 글

이 논문은 2020년 용인대학교 학술연구조성비 재원으로 수행된 연구임

References

- [1] H. Jeon, Y. Na, Y. Youn, K. Kim, H. Ahn, and J. Kim, "Study on Development for Smart Door Lock and App. using Arduino and Infrared Sensor," *The Journal of The Korea Institute of Electronic Communication Sciences*, vol. 17, no. 6, pp. 1199-1206, 2022.
- [2] S. Kim, M. Kim, K. Lee, B. Kwon, and H. Yoon, "Carbon Dioxide Fluctuation in Suncheon Bay Measured by Infrared and Ultrasonic sensors," *The Journal of The Korea Institute of Electronic Communication Sciences*, vol. 16, no. 1, pp. 157-164, 2021.
- [3] V. Voronin, M. Zhdanova, N. Gapon, A. Alepko, A. Zelensky, and E. Semenishchev, "Deep visible and thermal image fusion for enhancement visibility for surveillance application," *Electro-optical and Infrared Systems: Technology and Applications XIX*, vol. 12271, 2022, pp. 198-203
- [4] A. N. Wilson, K. Gupta, B. H. Koduru, A. Kumar, A. Jha, and L. R. Cenkeramaddi, "Recent advances in thermal imaging and its applications using machine learning: A review," *IEEE Sensors Journal*, vol. 23, no. 4, 2023, pp. 3395-3407.
- [5] X. Kuang, X. Sui, Y. Liu, Q. Chen, and G. Gu, "Single infrared image enhancement using a deep convolutional neural network," *Neurocomputing*, vol. 332, 2019, pp. 119-128.
- [6] Y. Choi, N. Kim, S. Hwang, and I. Kweon, "Thermal image enhancement using convolutional neural network," In *2016 IEEE/RSJ international conference on intelligent robots and systems (IROS)*, IEEE, Daejeon, Korea, Oct. 2016, p. 223-230.
- [7] J. Kim, J. Lee, and K. Lee, "Accurate image super-resolution using very deep convolutional networks," In *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, Las Vegas, NV, USA, June-July 2016, pp. 1646 - 1654.
- [8] K. Lee, J. Lee, J. Lee, S. Hwang, and S. Lee, "Brightness-based convolutional neural network for thermal image enhancement," *IEEE Access*, vol. 5, 2017, pp. 26867-26879.
- [9] Y. Ban and K. Lee, "Multi-Scale Ensemble Learning for Thermal Image Enhancement," *Applied Sciences*, vol. 11.6, 2021, pp. 2810.
- [10] J. Yang, J. Wright, T. S. Huang, and Y. Ma, "Image super-resolution via sparse representation," *IEEE transactions on image processing*, vol. 19, no. 11, 2010, pp. 2861-2873.
- [11] R. E. Rivadeneira, P. L. Suárez, A. D. Sappa, and B. X. Vintimilla, "Thermal image superresolution through deep convolutional neural network," *Image Analysis and Recognition: 16th International Conference, ICIAR 2019, Waterloo, ON, Canada, Aug. 2019*.
- [12] Y. Choi, N. Kim, S. Hwang, K. Park, J. Yoon, K. An, and I. Kweon, "KAIST multi-spectral day/night data set for autonomous and assisted driving," *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 3, 2018, pp. 934-948.
- [13] P. Cascarano, F. Corsini, S. Gandolfi, E. L. Piccolomini, E. Mandanici, L. Tavasci, and F. Zama, "Super-resolution of thermal images using an automatic total variation based method," *Remote Sensing*, vol. 12, no. 10, 2020, p. 1642.

저자 소개



이경재(Kyung-Jae Lee)

2011년 경희대학교 전자전파공학과 졸업(공학사)

2013년 연세대학교 대학원 전기전자공학부 졸업(공학석사)

2018년 연세대학교 대학원 전기전자공학부 졸업(공학박사)

2018년-2020년 삼성전자 무선사업부 책임연구원

2020년-현재 용인대학교 AI학부 교수

※ 관심분야 : 컴퓨터비전, 다중센서융합

