

Blurred Image Enhancement Techniques Using Stack-Attention

Park Chae Rim[†] · Lee Kwang Ill^{††} · Cho Seok Je^{†††}

ABSTRACT

Blurred image is an important factor in lowering image recognition rates in Computer vision. This mainly occurs when the camera is unstably out of focus or the object in the scene moves quickly during the exposure time. Blurred images greatly degrade visual quality, weakening visibility, and this phenomenon occurs frequently despite the continuous development digital camera technology. In this paper, it replace the modified building module based on the Deep multi-patch neural network designed with convolution neural networks to capture details of input images and Attention techniques to focus on objects in blurred images in many ways and strengthen the image. It measures and assigns each weight at different scales to differentiate the blurring of change and restores from rough to fine levels of the image to adjust both global and local region sequentially. Through this method, it show excellent results that recover degraded image quality, extract efficient object detection and features, and complement color constancy.

Keywords : Deblurring, Attention, Retinex, Color Constancy, Computer Vision

Stack-Attention을 이용한 흐릿한 영상 강화 기법

박 채 림[†] · 이 광 일^{††} · 조 석 제^{†††}

요 약

컴퓨터 비전에서 흐릿한 영상은 영상 인식률을 저하시키는 중요한 요인이다. 이것은 주로 카메라가 불안정하게 초점을 맞추지 못하거나, 노출 시간동안 장면의 물체가 빠르게 움직일 때 발생한다. 흐릿한 영상은 시각적 품질을 크게 저하시켜 가시성을 약화시키며, 이러한 현상은 디지털카메라의 기술이 지속적으로 발전하고 있음에도 불구하고 빈번하게 일어난다. 본 논문에서는 합성곱 신경망으로 설계된 심층 멀티 패치 계층 네트워크(Deep multi patch hierarchical network)를 기반으로 수정된 빌딩 모듈을 대체하여 입력 영상의 디테일을 잡고 주의 집중 기법을 도입하여 흐릿한 영상 속 물체에 대한 초점을 다방면으로 맞추어 영상을 강화한다. 이것은 서로 다른 스케일에서 각각의 가중치를 측정 및 부여하여 흐림의 변화를 차별적으로 처리하고 영상의 거친 수준에서 미세한 수준까지 순차적으로 복원하여 글로벌한 영역과 로컬 영역 모두 조정한다. 이러한 과정을 통해 저하된 화질을 복구하고 효율적인 객체 인식 및 특징을 추출하며 색 항상성을 보완하는 우수한 결과를 보여준다.

키워드 : 디블러링, 주의 집중 기법, 레티넥스, 색 항상성, 컴퓨터 비전

1. 서 론

카메라 흔들림, 물체 움직임, 그리고 초점 이탈로 인해 영상이 흐려지는 현상은 사진을 찍을 때 가장 잦게 나타나는 문제다. 일반적인 요인으로는, 광량이 충분하지 않은 환경에서 영상 획득 시 센서의 노출 시간이 길어지게 되는데 이때 센서

의 흔들림에 의해 영상이 흐려지는 문제를 일으킨다. 이러한 영상은 촬영 시 가장 흔히 보는 문제로 영상의 노이즈를 높이고 정보의 손실이 생겨 가독성을 떨어뜨리고 물체의 색과 특징을 추출하는데 어려움이 있다.

흐릿한 영상을 뚜렷하게 복원하는 방법은 컴퓨터 비전 분야에서 상당한 연구가 이루어지고 있다. Kim 등의 연구에서는 모션이 국소적으로 선형 변화를 한다고 가정하여, 분할 없는 접근법을 제안하였고[1], K.Orest 등은 생상적 적대 신경망(GAN)을 이용하여 다양한 블러 소스를 모델링 할 수 있는 현실적인 합성 모션을 만드는 새로운 방법을 구현하였다[2]. J. Sun 등[3], A. Chakrabarti[4], 그리고 D. Gong[5] 등은 합성곱 신경망(CNN)을 기반 딥러닝을 이용하였다. J. Sun 등은 흐릿한 방향과 커널을 추정하였고[3], A. Chakrabarti는 모션 커널의 복잡한 푸리에 계수를 예측하여 푸리에 공간에

※ 이 연구는 한국해양대학교 연구년 전임교원 교내 연구비 지원을 받아 수행되었음.

※ 이 논문은 2022년 한국정보처리학회 ASK 2022의 "Stack-Attention을 이용한 Retinex 영상 강화 기법"의 제목으로 발표된 논문을 확장한 것임.

† 준 회 원 : 한국해양대학교 제어계측공학과 석사과정

†† 비 회 원 : 한국해양대학교 인공지능공학부 교수

††† 종신회원 : 한국해양대학교 제어자동화공학부 교수

Manuscript Received : July 20, 2022

First Revision : September 1, 2022

Accepted : September 12, 2022

* Corresponding Author : Cho Seok Je(sicho@kmou.ac.kr)

서 비 블라인드 리블러링을 수행하였다[4]. D. Gong등은 모션 흐림을 추정하기 위해 완전 합성곱 신경망(FCN)을 활용하였다[5]. 이러한 접근 방식들은 합성곱 신경망을 사용하여 불분명한 블러 함수를 추정한다. 앞서 언급한 연구들은 실험의 입력 영상이 대부분 밝고 선명한 영상들이다. 그러나 우리는 광량으로 인해 부분적으로 그들이 저있거나, 어두워서 물체의 형태를 감지할 수 없는 다양한 환경에서의 사진을 이용한다. 이러한 문제를 해결하기 위해 여러 경우를 고려하여 뚜렷한 영상을 얻을 수 있는 알고리즘을 제안한다.

본 논문에서는 네트워크의 입력 영상으로 들어가기 전, 레티넥스(Retinex)를 이용하여 영상을 보정한다. 이 알고리즘은 조명 성분은 줄이고 반사 성분은 늘리는 형태로 각각의 알맞은 비율을 설정하여 외부 환경으로 인해 어두워진 영역을 조정한다. 이러한 영상이 합성곱 신경망 기반으로 설계된 딥 멀티 패치 계층 네트워크(Deep multi-patch hierarchical network)의 입력으로 들어간다. 이때 영상 내에 있는 물체에 대한 초점을 자동으로 맞추기 위해 주의 집중 기법을 도입한다. 이것은 서로 다른 스케일에서 각각의 가중치를 측정 및 부여하여 흐림의 변화를 차별적으로 처리한다. 거친 수준에서 미세한 수준까지 영상의 구조를 복원하여 글로벌한 영역 뿐만 아니라 로컬 영역까지 조정하여 보다 뚜렷한 물체 인식과 색 향상성을 보존한다.

2. 매개변수 공유 및 중첩 모듈

G. Hongyon 등 연구는 중첩 스킵 연결(skip connection) 구조를 통해, 비선형 변환 모듈에 대한 중첩 스킵 연결 구조를 제안하였다. 이것은 뚜렷한 영상을 위한 특징 변환 모듈의 고차 수준의 잔차를 학습하였다[6].

$$x_n = x_{n-1} + F_n(x_{n-1}) \quad (1)$$

Fig. 1에서 X_{n-1} , X_n 및 F_n 는 잔차 단위 입력, 출력 그리고 잔차 함수이며 3차 함수를 나타낸다. 이것은 그전의 1차, 2차 잔차 함수를 통해 확장된 것이며 확장은 더 높은 차수의 잔차 함수를 도출하기 위해 수행된다. 영상이 입력으로 들어

오면 n 개의 잔차 함수를 거쳐 각 특징맵을 뽑아내고 그들 사이에서 잔차의 합을 X_n 에 담는다.

Fig. 1은 3차 잔차 함수를 보여준다. Fig. 1과 같은 구조들이 DenseNet[7]과 시각적으로 유사한 중첩 연결 구조인 것처럼 보이지만, 두 가지 차이점이 있다. 1) 스킵 연결을 통해 영상의 특징을 뽑아서 그들 사이에서 잔차를 구하는 것과, 2) 직접 연결한 링크의 수가 상대적으로 더 많고, 이것들은 컨볼루션 레이어 끝에 위치하고 있다. 이러한 특징들은 잔차 함수를 중첩 모듈로 그룹화하여 고차 레벨의 정보 흐림을 개선하고 네트워크 전체에 기울기 소실 문제를 효율적으로 처리할 수 있다.

본 논문에서는 기존 중첩 스킵 연결에 주의 집중 모듈을 도입하여 영상의 미세한 영역부터 거친 영역까지 성능을 개선하고 영상 속 물체에 대한 초점을 자동으로 맞춘다. 이것은 물체를 다방면으로 나타낼 수 있으며 표현력을 높일 수 있기 때문에 뚜렷한 결과 영상을 추출한다.

3. 흐릿한 영상(Blurred image) 향상 기법

본 논문에서는 다양한 환경에서 촬영한 영상들을 레티넥스를 이용하여 영상 보정을 거친 뒤, 합성곱 신경망 기반의 딥 멀티 패치 계층 네트워크의 입력으로 들어간다. 새롭게 설계된 인코더-디코더 아키텍처를 거쳐 추출된 결과 영상과 예측 영상 사이의 손실 값을 측정하여 Improver를 통해 역전파시켜 최종 영상을 추출한다.

3.1 레티넥스 (Retinex)

디지털카메라의 눈인 영상 센서는 영상에 포함된 휘도와 색채 정보의 양을 담는데, 이것은 한 화소당 빛을 받는 면적이 감소할수록 노이즈를 증가시킨다[8, 9]. 이로 인해 실제로 보는 영상과 디지털카메라로 촬영한 영상이 다르게 보이는 문제가 발생된다. 이러한 문제를 개선하기 위해 입력 영상이 네트워크의 인코더 입력으로 들어가기 전, 영상의 대조를 개선하는 과정을 거친다. 인간의 시각적 모델을 바탕으로 조명 성분의 영향을 줄이는 레티넥스 알고리즘을 통해 영상의 화질을 개선한다.




Fig. 1. Nested Skip Connection Structure

$$I = R \cdot L \quad (2)$$

Land 등의 실험에서는 인간 시각 기관이 인지하는 물체의 색이 광원과 물체의 반사 성분의 곱으로 나타낼 수 있음을 입증하였다[10]. 또한 인간의 시각 인지는 실제 가해진 자극치와 인지된 감각 사이에는 log 관계를 가진다는 Weber-Fechner의 법칙이 적용된다. Equation (2)의 반사 성분을 중심으로 표현하면 Equation (3)과 같이 표현할 수 있다.

$$R = \log\left(\frac{I}{L}\right) \quad (3)$$

$$R = \log(I) - \log(F^* I) \quad (4)$$

수식으로 표현하면 밝기(brightness) 영상 I는 광원 조명(illumination) 성분 L과 반사(reflectance) 성분 R의 곱으로 Equation (2)와 같다. 상기 식은 조명 성분을 추정할 수 있으며 산술적인 방법을 통하여 물체 고유의 색인 반사 성분을 알아낼 수 있음을 의미한다.

위의 Equation (3)의 log 뺄셈 법칙과 주변 함수를 이용해 나타내면 Equation (4)와 같다. 여기서 F^* 는 주변 영역의 조명 성분을 추정하는데 사용되며, 조명 성분을 추정하기 위해서 주로 가우시안 필터나 평균 필터를 사용한다. 본 논문에서는 가우시안 필터를 사용하였다. *는 컨볼루션으로, 원 영상과 가우시안 필터를 컨볼루션하여 조명 성분을 추정한다.

Fig. 2의 상단과 하단은 레티넥스를 적용 전과 후를 나타낸다. 상단 영상은 빛에 의해 높은 밝기를 가진 영역과 제안된 밝기로 인해 그림자가 그늘린 영역이 혼합되어 발생하기 때문에 물체 인식 기능이 저하된다. 이러한 조명 광원을 줄이고 반사 성분으로 영상을 보정하여 가독성을 높이는 것이 레티넥스 알고리즘의 역할이다.



Fig. 2. Retinex Algorithm Result Images

3.2 영상 디블러링

1) 스택-중첩 주의 집중 모듈

본 논문에서는 G. Hongyon 등 연구[6]에서 중첩 스킵 연결 모듈을 기반으로 Fig. 1의 3차 잔차 함수에 주의 집중 기법을 추가하여 새로운 스택-중첩 주의 집중 모듈(Stack-Nested Attention Module)을 생성한다.

기존의 중첩 스킵 연결은 합성곱 신경망에서 널리 사용되고 ResNet[11] 및 ResBlock[12, 13]에서 두 개 이상의 컨볼루션 레이어를 이용하여 객체 감지, 영상 디블러링 및 고해상도 영상을 출력한다. 중첩 모듈은 정보의 흐름을 개선하고 네트워크의 기울기 소실 문제를 효율적으로 처리할 수 있다. 또한 복잡하게 표현되어 있는 고수준 잔차 함수를 최적화하고 보다 쉽게 리모델링하여 각각의 네트워크 모델에서 흔히 볼 수 있는 특징 맵을 최하위 계층부터 최상위 계층으로 연결하여 전달한다. 이것은 더 나은 세부 정보를 재구성할 수 있는 핵심요소이다. 이러한 중첩 모듈은 흐릿한 영상 전역 범위의 디테일을 잡아주기 때문에 모든 영역에 동일한 가중치가 적용된다.

그러나 본 논문에서는 영상의 특징 맵 픽셀마다 각각 다른 가중치를 부여하여, 초점이 맞춰진 물체와의 차별을 두어야 한다. 그러므로 주의 집중 기법을 도입한다. 주의 집중 기법은 채널 모듈과 공간 모듈로 나뉘는데, 채널은 'what', 공간은 'where'에 집중한다. 이 두 가지를 혼합하면 물체의 디테일한 특징을 다방면으로 강조하여 뚜렷한 결과 영상을 나타낸다.

주의 집중 기법은 입력 영상을 Query(q), Key(k), Value(v)로 선형 변환하고 연산을 수행한다. Query는 현재 토큰, key는 query와 비교할 토큰이다. Key와 query 둘 사이의 유사성을 가중치로 측정하여 value에 담는다. Value는 각각 다른 가중합들을 할당하고 부여하여, 영상 내에 특정 부분의 차별적인 특징을 추출하고 물체의 표현력을 높인다. 이러한 과정을 패치별로 진행하면서 영상 속에서 무엇을 어디에 강조하거나 억제하는지를 학습하여 대상의 위치를 결정하고 객체 인식 및 특징 추출에 도움을 준다.

Fig. 3(a)는 레티넥스 알고리즘의 과정이다. 입력 영상의 조명 성분과 반사 성분을 분리하여, 조명 성분의 비율은 줄이고 반사 성분의 비율은 늘리는 작업을 통해 영상을 보정한다. Fig. 3(b)는 제안한 새로운 아키텍처로 여러 개의 중첩된 인코더-디코더를 나타낸다. 인코더에서는 입력 영상을 동일한 패치로 나누어 특징을 추출 및 분리한 뒤, 이를 기반으로 차별화된 가중치를 측정하고 쌓인다. 디코더에서는 분리된 특징 패치들을 중첩하고 재구성하는 역할을 한다. 이러한 과정을 거쳐 추출된 잔차가 상위 레벨의 입력으로 공급되는 원리이다. 이것은 영상의 특징 및 재구성, 비선형변환은 물론, 물

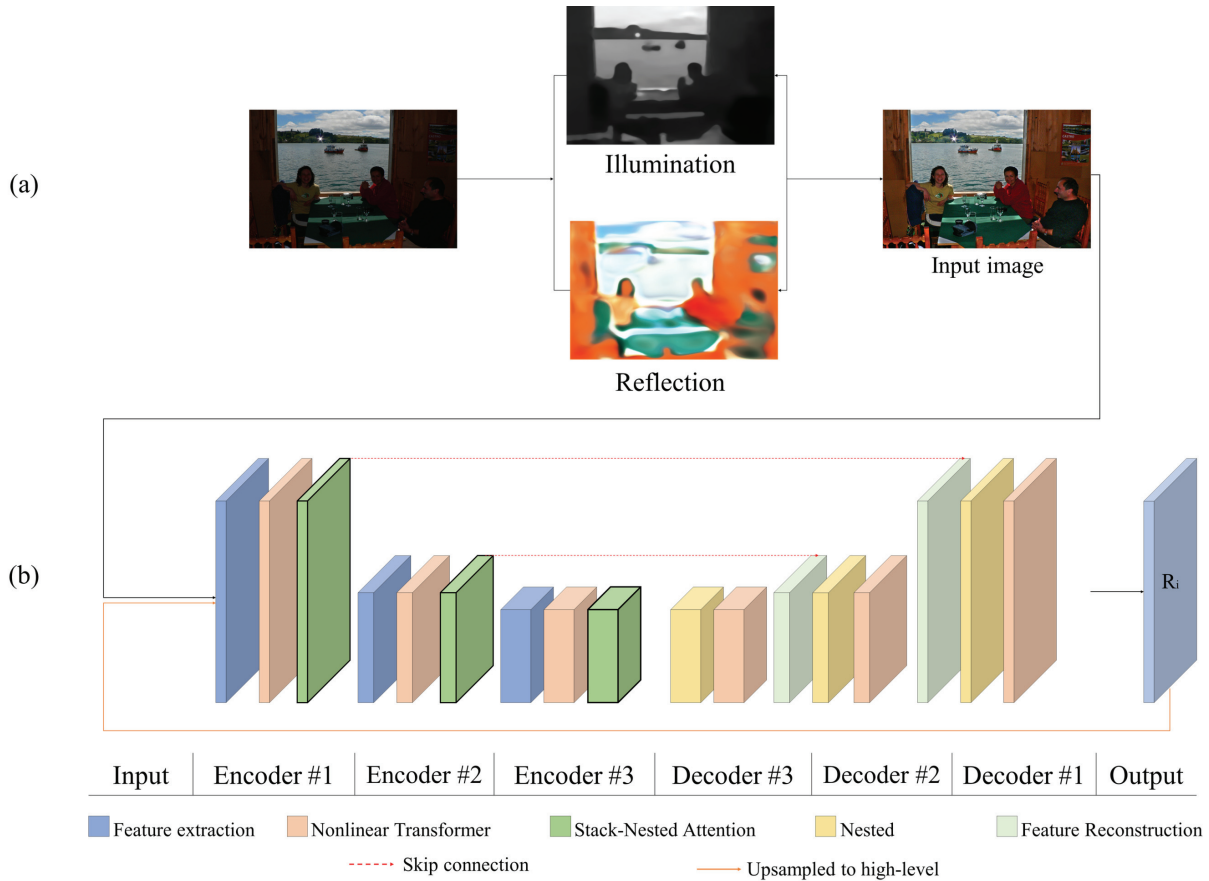


Fig. 3. Proposed Method Architecture

체에 대한 역동적인 모션을 잡기 위해 도입한 스택-중첩 주의 집중 모듈을 통해 패치마다 차별적인 가중치를 부여한다.

2) 멀티 패치 계층 네트워크

영상의 고수준 잔차까지 잡기 위해서는 네트워크가 거친 수준에도 접근할 수 있어야 한다. 이러한 문제를 잡기 위해 S. Nah 등[12]과 T. Xin 등[13]은 연구에서 영상을 더 작은 그리드로 분할해도 리블러링 성능이 향상되지 않고, 영상의 거친 수준은 경험적 손실이 적기 때문에 잔차 기여에 있어 제외된다는 사실을 관찰하였다. 이러한 문제를 해결하기 위해 딥 멀티 패치 계층 네트워크[14, 15]를 사용한다. 딥 멀티 패치 계층 네트워크는 다단계 네트워크로, Fig. 4와 같이 영상이 입력되면(Fig. 4에서 I) 각 레벨에서는 서로 다른 패치의 수에 대해 작동한다. 사용되는 패치의 수는 상위 레벨에서 하위 레벨까지 각각 1, 2, 4, 8개이다. 최상위 수준(레벨-1)은 영상 당 하나의 패치만 고려한다. 다음 수준(레벨-2)에서는 두 개의 패치를 수직으로, 다음 수준(레벨-3)에서는 수평으로 분할된다. 마지막 최하위 수준(레벨-4)에서는 수직으로 각각 분할되어 인코더-디코더의 상세한 아키텍처는 Fig. 4와 같으며 ‘!’ 기호는 공간 연결, ‘+’ 기호는 잔차 덧셈을 나타낸다. 각

각의 레벨마다 인코더를 통해 얻어진 잔차들의 합들이 중간 특징 맵을 생성하여 스택 형태로 누적되고, 디코더를 통해 추출된 잔차들은 상위 레벨 인코더의 입력으로 추가된다.

수정된 아키텍처를 기반으로 특정 수준의 독립적인 패치가 인코더의 입력으로 들어갈 때, 각각의 패치는 동일한 크기의 특징 맵을 나타내기 때문에 입력 시퀀스를 예측 영상과 관련 있는 픽셀을 치중해서 본다. 또한 디코더에 의해 출력된 잔차 기여도가 생성되어 이후 상위 레벨의 입력에 다시 추가되어 정제한다. 잔차가 상위 레벨에 추가될수록 영상의 거친 수준의 세부 영역까지의 정보가 포함되어 기존의 문제를 해결하고 뚜렷한 결과 영상을 얻을 수 있다. 마지막 레벨-1에서 결과 영상이 생성되면, 예측 영상과 비교하여 그 사이의 평균 제곱 오차(Mean Squared Error)를 통해 손실을 평가하고 Improver를 통해 역전파 한다.

3) Improver

Fig. 4의 레벨-1에서 추출된 영상과 예측 영상 사이의 손실 값이 발생하게 되는데, 본 논문에서는 그 사이에서 발생하는 오차를 Improver[16]를 통해 역전파 한다. 이것은 다중 퍼셉트론(Multi-Layer Perceptron, MLP)의 구조로 추출된

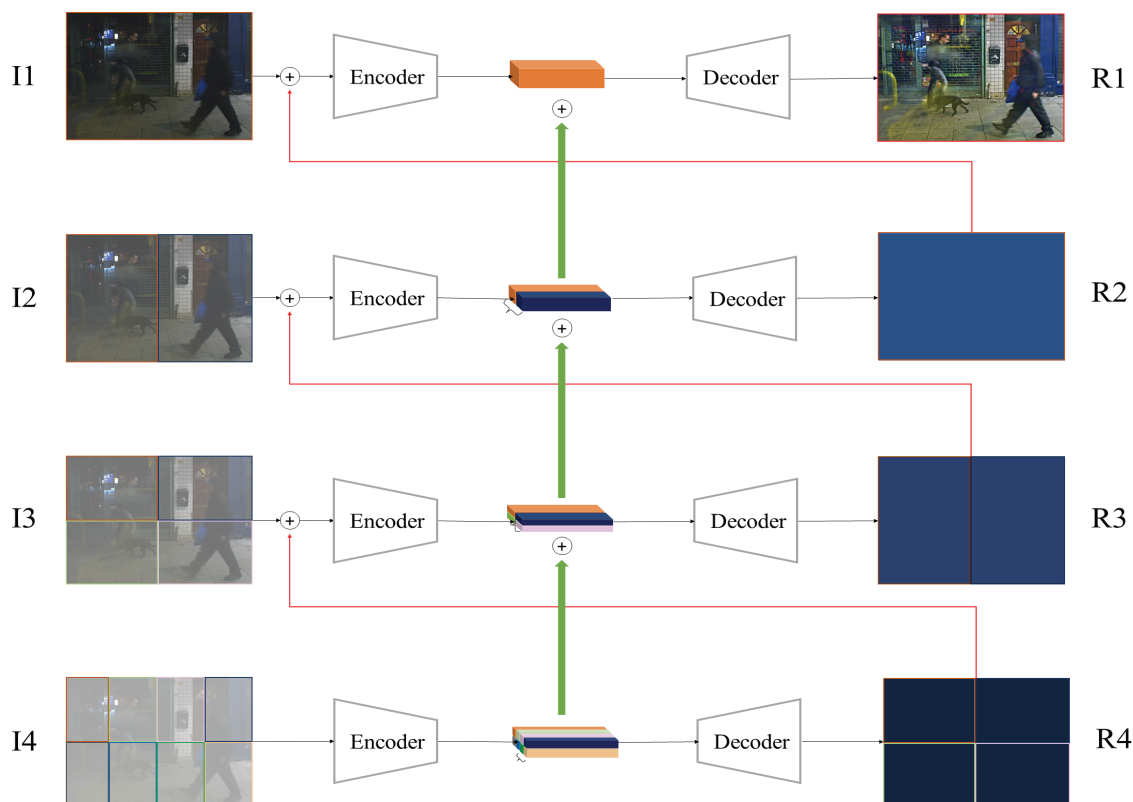


Fig. 4. Deep Multi-Patch Layer Network

영상에 대한 성능 개선의 중심 역할을 한다. 뒤에서 앞으로 가중치를 업데이트하는 역전파 알고리즘에 의해 훈련되어 존재하는 오류를 줄인다. Improver의 구조는 입력, 은닉 및 출력 레이어를 포함하는데, 이들 간의 관계는 완전하게 연결되어 있기 때문에 모든 가중치 값을 공유한다. 이들 사이에서 발생하는 손실 값이 얼마나 영향을 미치는지 정량적으로 계산한 다음 다시 역전파한다.

$$MSE = \frac{1}{n} \sum (O - G)^2 \quad (5)$$

둘 사이에서 존재하는 오차는 평균 제곱 오차를 이용하여 구한다. 이것은 추정 값 또는 모델이 예측한 값과 실제 환경에서 관찰되는 값의 차이를 다룰 때 사용하는 척도이며 각각의 영상들 사이에서 픽셀 값의 차이를 측정한다. 식(5)에서 n 은 크기, O 은 추출된 영상(Fig. 4에서 최종적으로 출력된 영상), G 는 예측 영상이다. Improver를 사용하여 추출 영상과 예측 영상 사이의 잔차를 판단한 후 역전파 한다.

이러한 과정은 패치 단위로 진행되기 때문에 매개 변수가 상대적으로 줄어들고 신속한 결과를 도출하여 피드백 할 수 있다. 최종적으로 추출된 영상은 기존에 얻었던 영상과는 달리 선명하고 자연스러운 영상을 얻는다.

Fig. 5는 앞서 언급한 알고리즘들을 순차적으로 적용한 것

이다. (a)는 입력 영상, (b)는 레티넥스를 적용한 영상, (c)는 Fig. 4와 같은 과정을 거쳐 최상위 계층에서 출력된 영상으로 Improver를 적용하기 전이고 (d)는 최종 영상이다. 레티넥스 알고리즘을 적용하여 영상의 전체적인 보정이 되었다는 것을 알 수 있다. 제안한 방법의 알고리즘을 적용하여 해당 영역에 대한 초점을 자동으로 맞춰 선명한 결과를 얻는다. 마지막으로 Improver를 이용하여 얼룩지고 부자연스러운 부분을 잡아주었다.

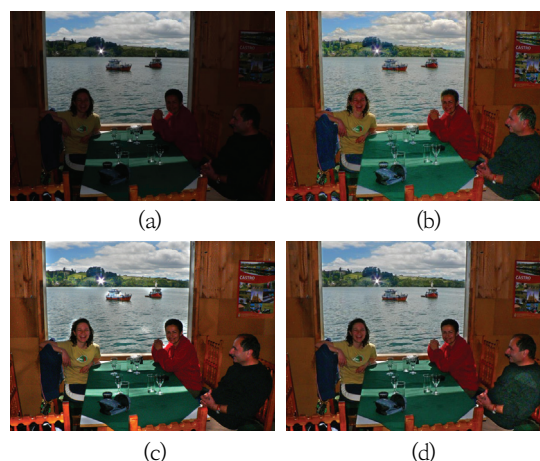


Fig. 5. (a)Input Image, (b)Retinex Image, (c)Image Before Applying Improver, (d)Result Image

4. 실험 및 고찰

본 논문에서 실험한 데이터 셋은 DICM[17], ExDark[18], VV[19]를 혼합하여 훈련 데이터와 테스트 데이터가 겹치지 않게 실험을 진행했다. Fig. 6의 (a)는 입력 영상, (b)는 Improver를 적용하기 전, (c)는 최종 영상이다.

Fig. 6의 첫 번째 영상은 표지판과 사람, 두 번째 영상과 세 번째 영상은 자전거를 타고 있는 사람에게 초점이 잡혔다. Improver를 적용하기 전 영상인 (b)는 영상 자체에 얼룩진 부분이 많아서 어색한 반면 (c)는 자연스러운 영상이 출력되었다.

수치화된 기준으로 성능 SSIM과 PSNR을 이용하여 비교 평가하였다.

SSIM은 이미지 품질 평가를 위한 방법으로 휘도, 대비, 구조를 비교하여 시각적 화질 차이 및 유사도를 평가하기 위해 고안되었다. PSNR은 신호가 가질 수 있는 최대 전력 잡음을 나타내며 영상의 화질 손실 정보를 평가할 때 사용한다.

제안한 방법의 성능을 평가하기 위해 다른 연구들을 참고하였다. 첫 번째, G. Hongyun 등의 연구는 뚜렷한 영상을



Fig. 6. Results of Applying the Proposed Method (a) Input Image, (b) Image Before Applying Improver, (c) Result Image

Table 1. Quantitative Evaluation of Proposed Method

	Our	[6]	[13]	[20]	[21]
SSIM	0.931	0.942	0.618	0.566	0.902
PSNR	31.69	31.58	28.51	20.26	30.04

위해 중첩 스킵 연결 구조를 사용하여 특징 변환 모듈의 고차 수준의 잔차를 학습하였고[6], 두 번째로 T. Xin 등의 연구는 새로운 네트워크를 제안하여 영상의 조밀한 부분부터 미세한 부분까지 점진적으로 복원하였다[14]. 그리고 세 번째, G. Tiantong 등의 연구는 새로운 두 가지 네트워크를 개발하여 손상된 영상을 복구하였다[20]. 마지막 H. Zhang 등 연구는 심층 계층 멀티 패치 네트워크를 제안하여 흐릿한 영상을 미세하게 처리하였다[21].

SSIM은 G. Hongyun 등[6]과 비교하였을 때 0.011 낮았지만 T. Xin 등[14], G. Tiantong 등[20], 그리고 H. Zhang 등[21]과 비교하였을 때 우수한 결과를 보였다. 또한 PSNR은 가장 뛰어난 성능을 보여주는 것을 Table 1에서 확인했다.

본 논문에서는 광원 자체의 밝기가 낮거나 드리워진 그림자 등의 이유로 어두운 영역을 포함하고 있는 영상을 레티넥스 알고리즘을 통해 영상을 보정하여 물체의 색 항상성을 보유했다. 이런 보정된 영상을 새로운 아키텍처로 설계된 딥 멀티 패치 계층 네트워크의 입력으로 들어가는 과정을 거침으로써 상대적인 움직임으로 인한 흐린 부분을 미세하게 잡아 주었다. 최종 복원된 결과 영상을 통해 가독성과 정확성을 높였음을 확인하였다.

5. 결론

컴퓨터 비전의 문제 중 하나인 흐릿한 영상은 빈번하게 일어나는 문제이다. 이러한 문제를 해결하기 위해 레티넥스로 보정된 영상을 새로운 아키텍처가 있는 딥 멀티 패치 계층 네트워크를 생성하였다. 네트워크를 거쳐 추출된 영상은 거친 수준에서 미세한 수준까지 영상의 구조를 복원하여 글로벌한 영역부터 로컬 영역까지를 조정한다. 이를 통해 상대적인 움직임으로 인해 저하된 화질을 복구하고 효율적인 객체 인식 및 특징을 추출하며 물체의 색 항상성을 효과적으로 보완한다. 정성적 결과뿐만이 아닌 정량적 지표를 통해 SSIM과 PSNR는 0.931과 31.69의 우수한 결과를 도출하였다.

References

[1] T. H. Kim and K. M. Lee, "Segmentation-free dynamic scene deblurring," In *Computer Vision and Pattern Recognition*, pp.2766-2773, 2014.

- [2] K. Orest, B. Volodymyr, M. Mykola, M. Dmytro, and M. Jiri, "DeblurringGAN: Blind motion deblurring using conditional adversarial network," In *Computer Vision and Pattern Recognition*, 2018.
- [3] J. Sun, W. Cao, Z. Xu, and J. Ponce, "Learning a convolutional neural network for non-uniform motion blur removal," In *Computer Vision and Pattern Recognition*, 2015.
- [4] A. Chakrabarti, "A Neural Approach to Blind Motion Deblurring," In *European Conference on Computer Vision*, 2016.
- [5] D. Gong, J. Yang, L. Liu, Y. Zhang, I. Reid, C. Shen, A. Van, and Q. Shi, "From motion blur to motion flow: A deep learning solution for removing heterogeneous motion blur," *Computer Vision and Pattern Recognition*, 2016.
- [6] G. Hongyun, T. Xin, S. Xiaoyong, and J. Jiaya, "Dynamic scene deblurring with parameter selective sharing and nested skip connections," In *Institute of Electrical and Electronics Engineers*, IEEE, 2019.
- [7] G. Huang, Z. Liu, L. Van, and K. Q. Weinberger, "Densely connected convolutional networks," In *Computer Vision and Pattern Recognition*, pp.4700-4708, 2017.
- [8] M. Y. Lee, C. H. Son, J. M. Kim, C. H. Lee, and Y. H. Ha, "Illumination-level adaptive and flare compensation for mobile display," *Journal of Imaging Science and Technology*, Vol.51, No.1, pp.44-52, 2007.
- [9] D. Wandell, P. Catrysse, J. Dicarolo, D. Young, and A. E. Gamal, "Multi capture single image with a CMOS sensor," *Chiba Conference on Multispectral Imaging*, pp.11-17, 1999.
- [10] E. Land and J. McCann, "Lightness and retinex theory," *Journal of the Optical Society of America A*, Vol.61, No.1, pp.1-11, 1971.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," In *Computer Vision and Pattern Recognition*, pp.770-778, 2016.
- [12] B. Lim, S. Son, H. Kim, S. Nah, and K. M. Lee, "Enhanced deep residual networks for single image super-resolution," In *Computer Vision and Pattern Recognition Workshop*, 2017.
- [13] S. Nah, T. H. Kim, and K. M. Lee, "Deep multi-scale convolutional neural network for dynamic scene deblurring," In *Computer Vision and Pattern Recognition*, pp.3883-3891, 2017.
- [14] T. Xin, G. Hongyun, S. Xiaoyong, W. Jue, and J. Jiaya, "Scale-recurrent network for deep image deblurring," In *Computer Vision and Pattern Recognition*, pp.8174-8182, 2018.
- [15] D. Sourya and D. Saikat, "Fast deep multi-patch hierarchical network for non-homogeneous image dehazing," In *Computer Vision and Pattern Recognition Workshop*, 2020.
- [16] C. R. Park, J. H. Kim, and S. J. Cho, "Improving colorization through denoiser with MLP," In *Journal of Advanced Marine Engineering and Technology*, pp.1-7, 2022.
- [17] DICM Dataset [Internet], paperswithcode.com/dataset/dicm
- [18] ExDark Dataset [Internet], paperswithcode.com/dataset/exdark
- [19] VV Dataset [Internet], sites.google.com/site/vonikakis/datasets
- [20] G. Tiantong, L. Xuelu, C. Venkateswararao, and M. Vishal, "Dense scene information estimation network for dehazing," In *Computer Vision and Pattern Recognition*, 2019.
- [21] H. Zhang, Y. Dai, H. Li, and P. Koniusz, "Deep stacked hierarchical multi-patch network for image deblurring," In *Computer Vision and Pattern Recognition*, pp.5578-5986, 2019.
- [22] C. R. Park, K. I. Lee, and S. J. Cho, "Retinex image enhancement techniques using stack-attention," In *Korea Information Processing Society*, Vol.29, No.1, pp.443-445, 2022.



박 채 림

<https://orcid.org/0000-0001-9985-3967>

e-mail : cofla7572@naver.com

2021년 한국해양대학교 제어자동화공학부 (학사)

2021년 ~ 현 재 한국해양대학교 제어계측공학과 석사과정

관심분야 : Computer vision, Image processing, Color engineering



이 광 일

<https://orcid.org/0000-0002-8307-9003>

e-mail : leeki@kmou.ac.kr

1993년 충남대학교 컴퓨터과학과(학사)

1996년 충남대학교 컴퓨터과학과(석사)

2001년 충남대학교 컴퓨터과학과(박사)

2000년 ~ 2002년 NIST, Researcher

2002년 ~ 2004년 University of maryland, Researcher

2004년 ~ 2006년 University of Texas, Researcher

2006년 ~ 2017년 한국전자통신연구원 책임연구원

2017년 ~ 현 재 한국해양대학교 인공지능공학부 교수

2019년 ~ 현 재 한국지능시스템학회 이사

관심분야 : Maritime Autonomous Surface Ship, E-navigation, Marine Cybersecurity & Safety Probability, Smart Ship



조 석 제

<https://orcid.org/0000-0001-9979-2252>

e-mail : sjcho@kmou.ac.kr

1982년 경북대학교 전자공학과(학사)

1988년 경북대학교 전자공학과(석사)

1991년 경북대학교 전자공학과(박사)

1982년 ~ 1988년 금성전선연구소 연구원

1991년 ~ 현 재 한국해양대학교 제어자동화공학부 교수

2010년 ~ 2011년 한국해양대학교 IT공학부 학부장

2004년 ~ 2005년 한국해양대학교 정보전산원장

관심분야: Digital Image Processing, 3D Image Processing,
Stereo Vision, Computer Vision, Color
Engineering