

공간 적응적 조건부 적대적 생성신경망을 활용한 단일 영상 내 반사 영역 제거기법

김 태 현*, 윤 종 수*, 최 윤 식°

Single Image Reflection Removal via the Spatially Adaptive Conditional Generative Adversarial Network

Taehyeon Kim*, Jongsu Yoon*, Yoonsik Choe°

요 약

단일 영상 내 반사 영역 제거는 영상처리 및 컴퓨터 비전에서 중요한 문제이다. 이 문제를 해결하기 위해 본 논문은 해당 문제를 영상데이터 간 전환 문제로 정의한다. 다양한 영상데이터 간 전환 문제에서 조건부 적대적 생성신경망은 높은 성능을 달성하였으며, 이에 본 논문 또한 공간 적응적 비 정규화 기법을 활용한 조건부 적대적 생성신경망을 활용하여 단일 영상 내 반사 영역 제거방법을 제안한다. 반사 영역 제거와 관련된 공인 데이터 세트를 활용한 실험에서 제안된 방법은 기존 방법보다 높은 성능을 가지는 것을 확인할 수 있다.

키워드 : 조건부 적대적 생성신경망, 영상데이터 간 전환, 반사 영역 제거, 공간 적응적 비 정규화

Key Words : Conditional generative adversarial network, Image-to-image translation, Reflection removal, Spatially adaptive de-normalization

ABSTRACT

Reflection removal on a single-image has been a significant problem in image processing and computer vision. To solve this problem, the proposed algorithm defines single-image reflection removal as an image-to-image translation problem. In image-to-image translation, the conditional generative adversarial network (CGAN) achieves remarkable performance in various applications. Therefore, the proposed algorithm is based on CGAN with spatially adaptive de-normalization (SPADE), which solves the wash-away problem due to normalization layers. In the experimental results, the proposed algorithm shows better performance than the conventional methods.

1. 서 론

최근 빅 데이터 기술과 신경망 기술의 발전과 더불어 다양한 연구 및 산업 분야에서 컴퓨터 비전 (computer vision) 기술이 높은 성능을 달성하고 있

며, 카메라를 통해 취득된 영상데이터의 정제 (purification) 및 향상 (enhancement)을 위한 사전처리 기술 또한 그 중요성이 매우 증대되었다. 왜냐하면, 영상데이터의 사전처리 기술은 컴퓨터 비전 알고리즘의 성능뿐만 아니라 다양한 환경에서 취득한 영상데

※ 본 연구는 문화체육관광부 및 한국 콘텐츠진흥원의 연구개발지원사업으로 수행되었음(과제번호: R2020040238)

• First Author : Yonsei University Department of Electrical & Electronic Engineering, pyomu@yonsei.ac.kr, 학생회원

° Corresponding Author : Yonsei University Department of Electrical & Electronic Engineering, yschoe@yonsei.ac.kr, 중신회원

* Yonsei University Department of Electrical & Electronic Engineering, lyjlsl@yonsei.ac.kr, 정회원

논문번호 : 202012-295-A-RU, Received November 27, 2020; Revised December 13, 2020; Accepted December 20, 2020

이터에서 같은 성능을 유지할 수 있는 강인함 (robustness) 성능에도 밀접한 관련이 있기 때문이다. 본 논문은 영상데이터의 사전처리 기술 중 영상 내 반사 영역을 제거 (reflection removal) 문제를 해결하는 방법을 제안한다. 반사 영역 제거 문제란 유리창과 같이 빛의 반사가 있는 매질을 통해 사용자가 희망하는 피사체의 사진을 찍을 경우, 영상 내 의도하지 않은 불필요한 객체 정보 또한 필수불가결하게 포함되는 문제를 의미한다. 인간의 시각 시스템 (human visual system)은 평생 학습된 경험을 바탕으로 수준 높은 처리시스템을 통해 반사된 객체와 사용자가 희망한 피사체를 구분하여 인식할 수 있으나 컴퓨터 비전의 경우 이미지 반사를 구분하는 것은 상당히 복잡한 문제에 속한다. 왜냐하면, 유리에 반사되는 불필요한 객체의 정보들은 유리의 반사율, 유리의 두께, 조도, 카메라와 유리 사이의 거리 등 수 많은 요인에 의해 영향을 받는 물리적 현상이며, 이를 분리하기 위한 정교한 물리적 모델을 정의하는 것은 불가능에 가깝기 때문이다.

위의 문제를 해결하기 위해서, 다수의 선행연구는 저차원 분해 (low-rank decomposition), 가우시안 혼합 모델 (Gaussian mixture model) 등 다양한 기법을 활용한 연구결과들^[1,2,3,11]을 발표하였고 이들 모두 반사 영역 제거 문제의 복잡도를 완화하여 새로운 문제로 정의한 후 최적화 과정을 통해 반사 영역을 제거하려고 했으나, 각 방법에서 가정한 시뮬레이션 상황과 일치된 영상데이터에서만 의미 있는 성능을 보일 뿐 실제 영상데이터에서는 성능이 제한되는 문제점이 있다.

본 논문은 최근 반사 영역 제거의 연구 동향처럼, 심층신경망 (deep neural network)를 활용한 방법을 제안한다. 제안하는 방법은 반사 영역 제거 문제를 영상데이터 간 전환 문제 (image to image translation problem)로 정의한다. 따라서, 반사 영역이 포함된 영상데이터와 포함되지 않은 영상데이터를 각각 서로 다른 영상데이터 군집이라고 정의한 후 반사 영역이 포함된 영상으로부터 반사 영역이 제거된 영상데이터로의 변환을 가능케 하는 함수를 심층신경망을 통해 추정하고자 한다. 이를 위해, 본 논문에서 제안하는 반사 영역 제거기법은 조건부 적대적 생성신경망 (conditional generative adversarial network)을 활용하고자 한다^[4]. 조건부 적대적 생성신경망의 생성기 (generator)는 어떠한 조건이 주어지는 가정에서 표현되는 특정 데이터의 확률 분포를 추정하기 위해 설계 되었으며, 본 논문에서는 위의 조건을 반사 영역이 포함된 영상데이터로 상정하고 특정 데이터의 확률 분

포를 반사 영역이 제거된 영상데이터로 지정한다.

기존 조건부 적대적 생성신경망에서는 생성기의 학습 수렴을 위하여 배치 정규화 (batch normalization)^[7], 인스턴스 정규화 (instance normalization)^[8] 등 다양한 정규화 층을 활용함으로써 학습의 수렴을 유도했다. 하지만, 반사 영역 제거와 같이 입력 영상의 다양한 특징과 공간적 특징 (spatial feature)에 매우 민감한 활용 분야에서는 위와 같은 정규화 과정이 입력 영상 내 존재하는 다량의 정보를 오히려 손실하는 문제점을 불러일으켜 생성기로부터 나오는 출력 영상의 품질을 저하하는 문제를 발생하게 된다. 위와 같은 문제들을 해결하기 위해 생성기를 구성하는 디코더 (decoder)에 인코더 (encoder)의 특성-맵 (feature-map)을 결합하는 형태의 신경망 구조^[4,5,9]가 제안되었지만, 인코더는 입력 영상데이터를 잠재적 특성 공간 (latent feature space)에 투사 하는 것을 목적으로 하기 때문에 디코더의 특성-맵에 단순히 결합하는 것은 입력 영상의 공간적 특징을 일부 반영할 수는 있으나 근본적인 해결방안이 될 수 없다.

본 논문은 위의 입력 영상데이터의 공간적 특징 손실을 방지하기 위하여 공간 적응적 비 정규화 (spatially adaptive de-normalization)를 활용한다. 공간 적응적 비 정규화는 디코더의 특성-맵에 별도의 과정으로 구해진 입력 영상의 특성-맵을 계층적으로 요소별 연산을 통해 결합함으로써 생성기 내의 디코더에서 입력 영상의 다양한 공간적 특징을 활용할 수 있도록 한다. 따라서, 반사 영역 제거와 같이 입력 영상을 구성하는 다양한 다수의 특징 정보들이 정규화 과정에서 손실되는 문제점을 원천적으로 해결이 가능할 뿐만 아니라, 다양한 해상도의 특성-맵을 디코더의 특성-맵에 결합하기 때문에 정밀한 반사 영역 제거가 가능하다.

본 논문은 반사 영역 제거의 공인 데이터 세트를 활용한 실험결과를 포함하고 있으므로, 제안하는 방법의 뛰어난 성능을 정성 및 정량적으로 나타내었다.

II. 본 론

본 장에서는 단일 영상 내 반사 영역 제거 문제를 영상데이터 간 전환 문제로 정의하는 것과 조건부 적대적 생성신경망을 활용하여 영상데이터 간 전환 문제에 적용한 기존 방법들에 대해 다룬 뒤 본 논문에서 제안하는 반사 영역 제거방법인 “공간 적응적 조건부 적대적 생성신경망을 활용한 단일 영상 내 반사 영역 제거기법”에 대해 설명한다.

2.1 단일 영상 내 반사 영역 제거 문제

단일 영상 내 반사 영역 제거 문제 (single-image reflection removal problem)는 아래와 같이 표현된다.

$$I = \alpha T + \beta R + n \quad (1)$$

위 식에서 I 는 영상데이터, T 와 R 은 각각 투과 정보 (transmission)과 반사 정보 (reflectance)를 의미한다. α 와 β 는 각 영상 정보들의 가중치를 의미하고 n 은 영상 내 잡음 (noise)를 나타낸다. 위의 수식과 같이 단일 영상 내 반사 영역 제거 문제는 영상데이터가 투과 정보와 반사 정보의 선형 결합 (linear combination)으로 정의하고, 영상데이터 I 에서 투과 정보 T 를 추정하는 것을 목적인다. 위 문제 정의의 이해를 돕기 위해 해당 내용을 그림 1에 나타낸다.

2.2 영상데이터 간 전환 문제

영상데이터 간 전환 문제 (image to image translation problem)란 사용자가 정한 두 영상데이터의 도메인 간의 사상 (mapping)을 구하는 것이 목표인 컴퓨터 비전 문제 중 한 종류이다. 본 논문은 입력 영상데이터 도메인을 투과 정보 T 와 반사 정보 R 의 선형 결합으로 표현되는 영상 I 로 설정하고 출력 영상데이터 도메인을 최적의 투과 정보 T^* 로 설정함으로써 이 둘의 대치를 나타내는 최적 함수 $f^*(I)$ 를 심층신경망을 통해서 추정하는 것을 목적으로 하며, 이는 아래의 수식을 통해 표현할 수 있다.

$$f^*(I) \approx DNN(I) \quad (2)$$

위 식에서 $f^*(I)$ 는 입력 영상데이터를 최적의 투과 정보 T^* 로 대치하는 함수를 의미하고, $DNN(I)$ 는 본 논문에서 활용하는 심층신경망을 나타낸다. 신경망을 활용한 영상데이터 간 전환 문제의 학습은 일반적인

지도학습 (supervised learning) 방식으로 학습을 진행하지 않고 일반적으로 조건부 적대적 생성신경망 (conditional generative adversarial network)을 활용하여 문제 해결을 한다.

2.3 영상데이터 간 전환을 위한 조건부 적대적 생성신경망

앞 절에서 다룬 바와 같이 영상데이터 간 전환 문제는 사용자가 정한 입력 영상데이터의 도메인과 출력 영상데이터의 도메인을 대치하는 함수를 추정하는 것이다. 도메인 간 대치함수를 추정하기 위해 기존 연구들은 조건부 적대적 생성신경망을 활용하였으며, 적대적 생성신경망의 목적 함수는 다음과 같이 정의된다.

$$L_{CGAN}(G, D) = E_{x,y}[\log D(x,y)] + E_{x,z}[\log(1 - D(x, G(x,z)))] \quad (3)$$

위 식에서 z 는 잡음, x 는 입력 영상데이터, y 는 입력 영상데이터와 짝을 이루는 영상데이터를 의미한다. 생성기 G 는 목적 함수를 최소화시키기 위해 학습을 진행하고 판별기 (discriminator) D 는 위 객체 함수를 최대화시키기 위해 학습을 진행한다. 이처럼 적대적 학습 (adversarial learning)이란 서로 다른 두 신경망 G 와 D 가 상반되는 학습 목표를 가지고 학습하는 방식을 의미한다. 앞 장에서 다룬 바와 같이 조건부 적대적 생성신경망은 기존의 적대적 생성신경망과 달리 어떠한 조건을 주었을 때 발생하는 확률 분포를 나타내는 조건부 확률 분포를 추정하기 위해서 제시된 기법이다. 이를 설명하기 위한 일반적인 적대적 생성신경망의 목적 함수는 다음과 같다.

$$L_{GAN}(G, D) = E_{x,y}[\log D(y)] + E_{x,z}[\log(1 - D(G(x,z)))] \quad (4)$$



그림 1. 단일 영상 내 반사 영역 제거
Fig. 1. Single-image reflection removal

수식 (3)과 (4)에서 보이는 차이점은 판별기의 입력 형태가 다르다는 점이다. 조건부 적대적 생성신경망의 경우 판별기의 입력에 생성기의 출력 $G(x,z)$ 와 생성기의 입력 x 도같이 포함하거나, 입력 영상데이터 x 와 짝을 이루는 영상데이터 y 를 함께 포함하여 입력받는다. 반면, 적대적 생성신경망에서 판별기는 오직 실제 영상데이터 y 혹은 생성기로부터 생성된 영상데이터 $G(x,z)$ 만을 입력받는다. 이와 같은 차이점을 통해 조건부 적대적 생성신경망의 판별기는 입력 영상과 출력 영상이 서로 올바른 짝을 이루는지 판별을 해야 하며, 생성기의 경우 입력받은 x 에 올바른 짝을 이루는 y 와 유사한 영상데이터를 생성하기 위해서 학습을 진행한다. 이를 통해 일반 적대적 생성신경망과 달리 조건부 적대적 생성신경망은 입력 영상데이터를 조건으로 활용하여 해당 조건에 만족하는 영상데이터 생성을 가능케 한다.

본 논문은 단일 영상 내 반사 영역 제거를 목적으로 하고 있으므로 아래와 같은 수식을 통해서 영상 간 전환 문제로 목적하는 문제를 해결한다.

$$L_{proposed}(G,D) = E_{x,y}[\log D(I, T^*)] + E_{x,z}[\log(1 - D(I, G(I,z)))] \quad (5)$$

위 수식에서 I 와 T^* 는 각각 입력 영상데이터와 그에 해당하는 투과 정보를 의미한다. 따라서 본 목적 함수를 통해 제안되는 생성신경망의 생성기 G 는 입력 영상데이터 I 를 그에 해당하는 투과 정보 T^* 로 대체시키는 함수 $f^*(I)$ 를 추정하도록 학습을 유도할 수 있다.

2.4 공간 적응적 조건부 적대적 생성신경망을 활용한 단일 영상 내 반사 영역 제거기법

수식 (5)에서 정의한 반사 영역 제거를 위한 목적 함수를 통해 조건부 적대적 생성신경망의 학습 방향성의 설정이 가능하다. 하지만, 조건부 적대적 생성신경망의 구조에 따라서 생성기 G 에서 획득하는 $G(x,z)$ 의 영상 품질 또한 결정되기 때문에, 본 논문에서는 복잡한 물리적 모델링 과정이 요구되는 단일 영상 내 반사 영역을 제거하기 위한 신경망 구조를 제안한다.

기존의 조건부 적대적 생성신경망의 구조에서는 다수의 배치 정규화^[7] 혹은 인스턴스 정규화^[8]를 활용하여 생성기 G 의 학습 수렴을 가속화 하였다. 그러나, 정규화 층이 신경망의 안정적인 수렴을 보장하는 특

성이 있음에도, 반사 영역 제거와 같이 생성기 G 가 복잡한 물리적 현상을 오직 입력 영상데이터만을 활용하여 추론해야 하는 경우 오히려 입력 영상데이터에 포함된 다수의 중요 정보를 손실시켜 생성기 G 의 추론 결과에 악영향을 미치게 된다. 이와 같은 문제를 해결하기 위해 본 논문은 공간 적응적 비 정규화^[5] (spatially adaptive de-normalization)를 활용하여 생성기의 수렴을 보장하고 입력 영상데이터의 정보 손실을 원천적으로 차단한다. 만약 생성기 G 를 구성하는 특성-맵을 F 라고 표기할 경우 공간 적응적 비 정규화 기법은 아래와 같이 표기된다.

$$SPADE(F, I) = \gamma(I) \otimes \frac{F - \mu_F}{\sigma_F} \oplus \beta(I) \quad (6)$$

위의 수식에서 μ_F 와 σ_F 는 공간 적응적 비정규화가 적용될 특성-맵 F 의 요소들을 전부 활용한 평균과 표준 편차를 의미한다. \otimes 와 \oplus 는 요소별 곱 (element wise multiplication)과 요소별 합 (element wise summation)을 나타낸다. 그러므로 $\gamma(I)$ 와 $\beta(I)$ 는 F 와 같은 가지기를 가지는 3차원 텐서를 의미하며, 위 두 텐서 또한 컨볼루션 층으로부터 구해지기 때문에 특성-맵과 같은 특징을 가진다. 위 수식에서 표현된 전체 과정은 그림 2를 통해 확인할 수 있다.

수식 (5)에서 표현된 바와 같이 공간 적응적 비 정규화 과정은 특정 특성-맵 F 를 정규화한 후, 요소별

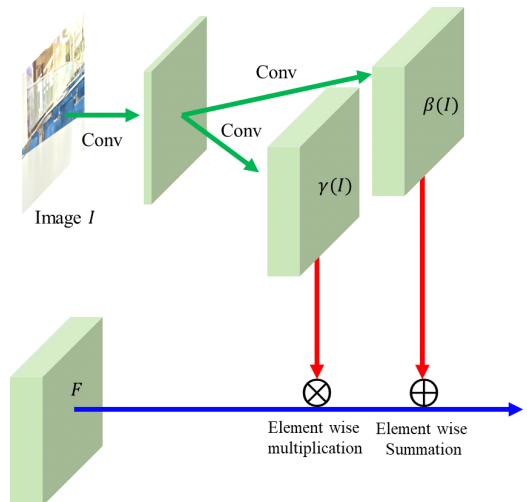


그림 2. 단일 영상 내 반사 영역 제거를 위한 공간 적응적 비 정규화 기법
Fig. 2. Spatially adaptive de-normalization for single-image reflection removal

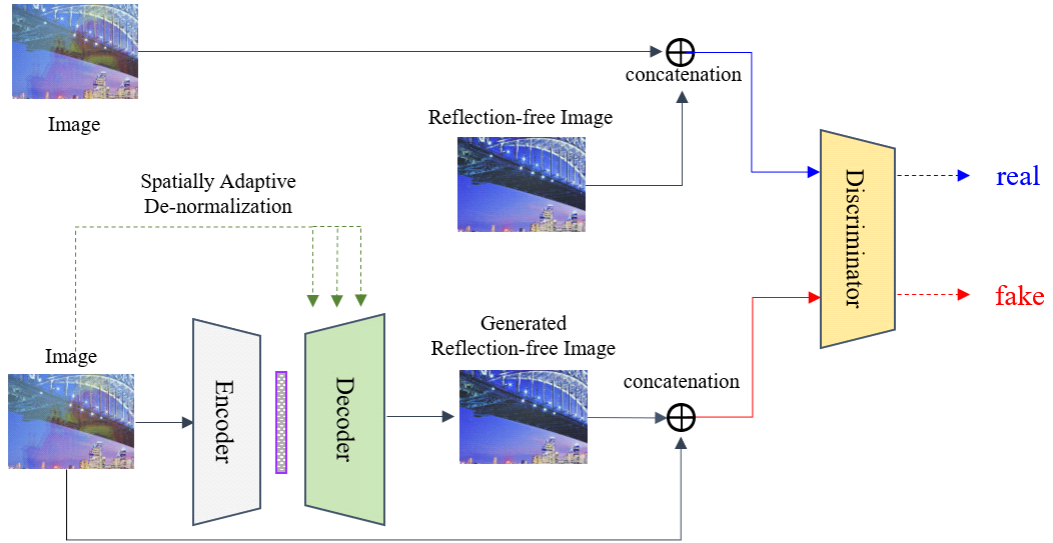


그림 3. 제안하는 알고리즘의 전체 구조: 공간 적응적 조건부 적대적 생성신경망을 활용한 단일 영상 내 반사 영역 제거기법
 Fig. 3. Overall architecture of proposed algorithm: single-image reflection removal via spatially adaptive conditional generative adversarial network

합과 곱 연산을 활용하여 입력 영상데이터의 특성-맵 정보를 삽입하는 것을 의미한다. 공간 적응적 비 정규화 기법을 활용할 경우, 생성기 G 를 구성하는 다수의 정규화 기법들로 인한 입력 영상데이터의 다양한 특징 정보들의 손실을 제한할 수 있을 뿐만 아니라, 생성기의 디코더를 구성하는 다양한 크기의 특성-맵에 적용하기 때문에 입력 영상데이터의 크기에 따른 계층적 특징 (hierarchical features) 또한 보장할 수 있다.

요약하자면, 본 논문은 단일 영상 내 반사 영역 제거를 위해 반사 영역 제거 문제를 영상데이터 변환 문제로 정의한다. 이를 위해 조건부 적대적 생성신경망을 활용하며 이때, 복잡한 물리적 현상으로 발생하는 정밀한 반사 영역 제거를 위하여 공간 적응적 비 정규화 기법을 생성기 G 에 추가함으로써 입력 영상데이터의 다양한 특징 정보를 삽입할 뿐만 아니라, 다양한 해상도의 입력 영상에게서 나오는 특성-맵을 활용함으로써 계층적 특징 또한 생성기의 디코딩 과정에 반영할 수 있도록 한다. 제안하는 반사 영역 제거기법의 전체 신경망 구조는 그림 3과 같이 표현된다.

III. 실험

3.1 실험 환경 및 구현 세부 정보

본 실험을 위해 Intel core i7 CPU와 GTX 1080 8GB GPU가 설치된 실험 환경을 구축하였다. 제안된 방법과 비교 실험을 위한 방법들의 구현은 PyTorch를

활용하였다. 비교 실험을 위해서 반사 영역 제거 공인 데이터 세트^[10]를 활용하였으며, 조건부 적대적 생성신경망 기반 방법^[4]과 최신 기법^[9]을 선정하여 비교 실험을 진행하였다. 생성된 그림자 제거 영상의 정량적 성능 비교를 위해 생성된 영상데이터와 그에 해당하는 라벨 영상데이터 간의 피크 신호 대 잡음 비 (PSNR)와 구조적 유사도 (SSIM)를 측정하였다. 모든 실험결과는 그림 4과 표 1에 요약하였다.

표 1. SIR²[10]에 대한 PSNR, SSIM 결과
 Table 1. PSNR and SSIM results on SIR² Dataset

	RM2S	Pix2Pix	Ours
PSNR (dB)	22.9	16.5	24.5
SSIM (%)	91.6	80.8	93.7

3.2 공인 데이터 세트를 활용한 반사 영역 제거

영상 내 반사 영역 제거를 위한 공인 데이터 세트는 SIR²[10]을 활용한다. 해당 데이터 세트는 총 500쌍의 영상데이터들로 구성되어 있다. 본 실험을 위해 500쌍의 영상데이터 중 400쌍을 학습용 데이터 세트로 지정하고, 나머지 100쌍의 영상데이터들을 시험용 데이터 세트로 구분하였다. 본 논문에서 제안하는 방법 및 두 비교 실험을 위한 기존 방법들은 총 100 Epoch 학습을 진행했으며, Adam 최적화 방법을 통해

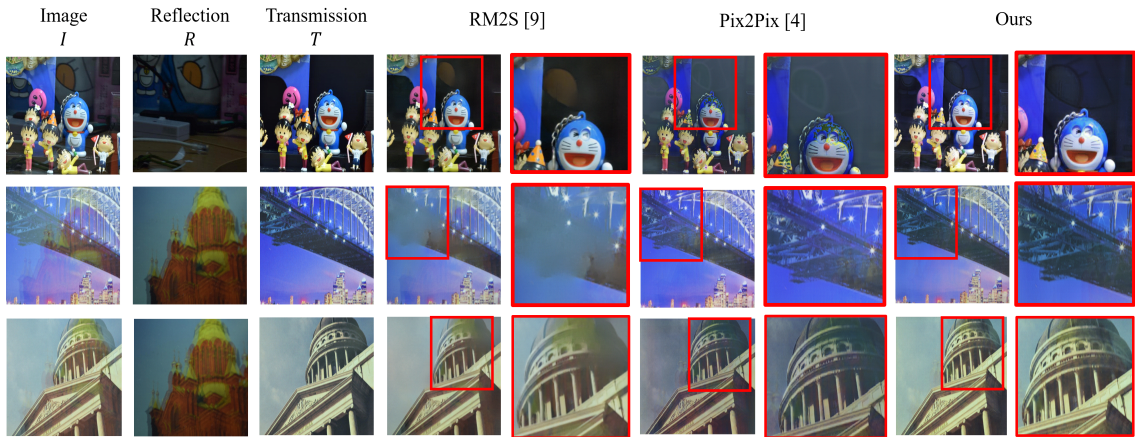


그림 4. SIR²[10]에 대한 실험결과
Fig. 4. Experimental results on SIR² Dataset

학습률 파라미터 (learning rate)를 조정하였다.

그림 4는 각각의 반사 영역 제거 알고리즘들이 입력 영상에 대해 어떠한 영상데이터를 생성했는지를 나타내고 있다. 그림 4에서 보이는 가장 큰 차이점은 RM2S^[9]의 경우 에지(edge)와 같은 영상 내 고주파 성분을 반사 영역이라고 판단하고 제거하는 경향이 있다는 것이다. 특히 이러한 현상은 2번째 열 실험에서 다리 아래에 존재하는 복잡한 철근 구조들을 지운 것을 통해서도 확인할 수 있다. 이와 달리, 제안된 알고리즘의 경우 다리 아래의 철근 구조물을 정확하게 복원하였으며, 그 이외의 영상 내 에지 성분들은 손실 없이 반사 영역만이 제거되는 것을 확인할 수 있다. 이는 RM2S 방법이 흐릿한 반사 영역에 존재하는 고주파 영상 성분들을 제거하기 위해 목적되어 있고, 이를 위해 입력 영상데이터의 기울기 성분 (gradient)들에 초점을 두고 있기 때문이다. 반면, 제안된 방법의 경우 RM2S 대비 간단한 신경망 구조를 활용하였으며 목적 함수 설계 시 반사 영역에 대한 별도의 특징 정보를 활용하고 있지 않음에도 불구하고 RM2S 보다 높은 성능을 보여주는 것을 확인할 수 있다.

같은 목적 함수로 학습을 시킨 Pix2Pix^[4] 실험의 경우 3개의 실험결과에서, 제안된 방법에 비해 낮은 반사 영역 제거 성능을 보인다. 이 문제는 Pix2Pix의 생성기에 포함된 다수의 정규화 층들이 입력 영상데이터의 공간적 정보를 손실시키기 때문에 발생하는 것으로 판단할 수 있으며, 반사 영역 제거 문제에서 제안하는 방법이 공간 적응적 비 정규화 기법을 활용하여 정규화 층으로부터 발생하는 정보 입력 영상데이터의 정보 손실문제를 해결했음을 반증한다. 각 방

법에 대한 정량적 실험 평가결과는 표 1에 정리 하였으며, 피크 신호 대 잡음 비, 구조적 유사도 평가 기준 모두에서 제안하는 방법이 비교 기법들보다 더 높은 성능을 달성하는 것을 확인할 수 있다.

IV. 결론

본 논문은 조건부 적대적 생성신경망을 활용한 반사 영역 제거기법을 제안한다. 이에 따라 기존의 단일 영상 내 반사 영역 제거 문제를 영상데이터 간 전환 문제로 문제를 정의하고 조건부 적대적 생성신경망 구조로 반사 영역 제거 문제를 해결한다. 추가로, 제안하는 방법은 정규화 층 구조로 인한 입력 영상데이터의 정보 손실문제를 극복하고 다양한 해상도에 대한 계층적 특징을 디코딩 과정에서 활용할 수 있도록 공간 적응적 비 정규화 기법을 활용한다. 그 결과 공인 데이터 세트를 활용한 실험에서 기존의 방법들보다 높은 정성 및 정량적 성능을 달성하는 것을 확인할 수 있다. 하지만, 제안하는 방법은 반사 영역 내의 에지 성분과 같은 고주파 성분을 확실하게 제거하지 못하는 제한점이 있으며 이는 추후 물리적 모델링 기반의 반사 영역 제거방법들과 적절한 상호보완적 결합을 통해 해결하고 자 한다.

References

- [1] N. Kong, Y.-W. Tai, and J. S. Shin, "A physically based approach to reflection separation from physical modeling to

constrained optimization,” *IEEE Trans. Pattern and Machine Intell.*, vol. 36, no. 2, pp. 209-221, 2013.

[2] X. Guo, X. Cao, and Y. Ma, “Robust separation of reflection from multiple images,” in *Proc. IEEE Conf. CVPR*, Jun. 2014.

[3] R. Wan, et al., “Sparsity based reflection removal using external patch search,” *IEEE ICME*, Hong Kong, 2017.

[4] P. Isola, et al., “Image-to-Image translation with conditional adversarial networks,” in *Proc. IEEE Conf. CVPR*, 2017.

[5] O. Ronneberger, et al., “U-net: Convolutional networks for biomedical image segmentation,” *Int. Conf. Med. Image Comput. and Computer-Assisted Intervention*, Springer, Cham, 2015.

[6] T. Park, et al., “GauGAN: Semantic images synthesis with spatially adaptive normalization,” in *Proc. IEEE Conf. CVPR*, 2019.

[7] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” *arXiv preprint arXiv: 1502.03167*, 2015.

[8] D. Ulyanov, et al., “Instance normalization: The missing ingredient for fast stylization,” *arXiv preprint arXiv: 1607.08022*, 2016.

[9] T. Li and Daniel P. K. Lun, “Single-image reflection removal via two-stage background recovery process,” *IEEE Sign. Process. Lett.*, pp. 1237-1241, vol. 26, no. 8, 2019.

[10] R. Wan, B. Shi, et al., “Benchmarking single-image reflection removal algorithms,” *Int. Conf. Computer Vision*, 2017.

[11] B. Han and J.-Y. Sim, “Reflection removal via active gradient reliability calculation,” *30th Wkshps. Image Process. and Image Understanding*, Feb. 2018.

김 태 현 (Taehyone Kim)



2017년 2월 : 강원대학교 전기공학과 졸업
 2017년 3월~현재 : 연세대학교 전기전자공학과 석·박사통합과정
 <관심분야> 컴퓨터 비전, 딥러닝, 텐서 분해법

[ORCID:0000-0001-5496-2625]


윤 종 수 (Jongsu Yoon)



2014년 8월 : 연세대학교 전기전자공학과 졸업
 2014년 9월~현재 : 연세대학교 전기전자공학과 석·박사통합과정
 <관심분야> 컴퓨터 비전, 비디오영상 신호 처리 및 해석

[ORCID:0000-0003-0845-937X]

최 윤 식 (Yoonsik Choe)



1979년 2월 : 연세대학교 전기공학과 졸업
 1984년 2월 : Case Western Reserve 대학, 시스템공학과 석사
 1987년 5월 : Pennsylvania 주립대학 전기 및 컴퓨터공학과 석사

1990년 12월 : Purdue 대학 전기 및 컴퓨터공학과 박사

1993년 3월~현재 : 연세대학교 전기전자공학과 교수
 <관심분야> 비디오/영상 신호 처리 및 해석, 통계적 영상신호처리

[ORCID:0000-0002-4856-8741]