

특집논문 (Special Paper)

방송공학회논문지 제26권 제1호, 2021년 1월 (JBE Vol. 26, No. 1, January 2021)

<https://doi.org/10.5909/JBE.2021.26.1.3>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

다중 도메인 학습을 이용한 화면 촬영 영상 내 모아레 무늬 제거 기법

박 현 국^{a)}, 비엔지아인^{a)}, 이 철^{a)‡}

Screen-shot Image Demoiréing Using Multiple Domain Learning

Hyunkook Park^{a)}, An Gia Vien^{a)}, and Chul Lee^{a)‡}

요 약

본 논문은 다중 도메인 학습을 이용하여 화면 촬영 영상 내 모아레 무늬를 효과적으로 제거하는 기법을 제안한다. 제안하는 기법은 먼저 화소값 영역과 주파수 영역에서 입력 영상의 모아레 무늬를 각각 제거한다. 다음으로 모아레 영상에서 **clean edge map**을 추정하고, 추정된 **clean edge map**을 가이드 정보로 사용하여 화소값 영역과 주파수 영역에서 얻은 결과 영상의 품질을 향상시킨다. 마지막으로, 독립적으로 향상된 두 결과 영상을 적응적으로 결합하며 모아레 무늬가 제거된 최종 결과 영상을 생성한다. 컴퓨터 모의 실험결과를 통해 제안하는 기법이 기존의 알고리즘보다 모아레 무늬를 더욱 효과적으로 제거할 수 있음을 확인한다.

Abstract

We propose a moire artifacts removal algorithm for screen-shot images using multiple domain learning. First, we estimate clean preliminary images by exploiting complementary information of the moire artifacts in pixel value and frequency domains. Next, we estimate a clean edge map of the input moire image by developing a clean edge predictor. Then, we refine the pixel and frequency domain outputs to further improve the quality of the results using the estimated edge map as the guide information. Finally, the proposed algorithm obtains the final result by merging the two refined results. Experimental results on a public dataset demonstrate that the proposed algorithm outperforms conventional algorithms in quantitative and qualitative comparison.

Keyword : Moire artifacts removal, demoiréing, convolutional neural network (CNN), multiple domain learning

a) 동국대학교 멀티미디어공학과(Dongguk University, Department of Multimedia Engineering)

‡ Corresponding Author : 이철(Chul Lee)

E-mail: chullee@dongguk.edu

Tel: +82-2-2260-3339

ORCID: <https://orcid.org/0000-0001-9329-7365>

‡ This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIP) (No. NRF-2019R1A2C4069806).

· Manuscript received November 23, 2020; Revised December 28, 2020
Accepted December 28, 2020.

1. 서 론

최근 디지털 영상 기술의 발전으로 디지털 카메라와 스마트폰을 이용하여 다양한 환경에서 사진을 촬영할 수 있다. 하지만, 디스플레이 화면을 디지털 카메라를 이용하여 촬영 시 카메라의 색상 필터 배열(CFA)과 디스플레이의 그리드 위치 차이로 인하여 앨리어싱 현상이 발생하며, 취득된 영상에 모아레(Moiré) 무늬가 포함되고 영상 전체의 색

상이 저하된다. 모아레 무늬는 그림 1이 예시하는 것과 같이 촬영된 화면에 무지개빛 또는 물결무늬의 출렁임 등 복잡한 형태와 다양한 색을 포함하여 나타나며, 영상의 품질을 저하시킨다. 따라서, 화면 촬영 영상에서 모아레 무늬를 제거하여 영상의 품질을 향상시키기 위해서 다양한 알고리즘이 개발되었다.

예를 들어 Schöberl 등은 카메라 센서 앞에 저역 통과 필터를 부착하여 앨리어싱 현상을 제거하는 기법을 제안하였다^[1]. 하지만 이 기법은 특수한 하드웨어를 필요로 하며 저역 통과 필터링으로 인해 고주파 성분이 제거되어 결과 영상이 과도하게 부드러워지는 문제를 발생시킨다. Pekkucuksen와 Altunbasak는 색상 차이 보간법을 기반으로 색상 필터 배열의 서브샘플링 기법을 제안하였다^[2]. 하지만 이 기법은 계산 복잡도가 높으며, 결과 영상이 녹색 채널에 과도하게 의존하여 실제 애플리케이션에 적용이 어려운 단점이 있다. 최근의 CNN (Convolutional neural network) 기반 알고리즘은 대규모 데이터셋 학습을 통하여 우수한 성능을 보인다. 예를 들어, Sun 등은 대량의 데이터셋으로 네트워크를 학습하여 모아레 무늬를 제거하는 기법을 제안하였고^[3], Cheng 등은 동적 특징 인코딩 모듈을 적용하여 모아레 영상과 Ground-truth 영상 사이의 차이를 임베딩하여 모아레의 복잡한 무늬를 제거하였다^[4]. He 등은 영상의 에지 정보와 모아레 무늬의 다양한 특성을 고려하였다^[5]. Zheng 등은 학습 가능한 대역 통과 필터를 사용하여 모아레 무늬를 주파수 영역에서 학습하며 모아레를 제거하였다^[6]. 이러한 기존 기법들은 공통적으로 강한 색과 형태의 모아레 무늬는 효과적으로 제거하지 못할 뿐만 아니라, 학습 데이터를 촬영한 카메라의 설정과 다르게 촬영된 영상에 대해서는 품질이 저하되는 단점이 있다.

본 논문은 다중 도메인 학습을 이용한 화면 촬영 영상 내 모아레 무늬를 효과적으로 제거하는 기법을 제안한다. 제안하는 기법은 Pixel Network, Edge Network, DCT Network, Refinement Network로 구성되며, 서로 다른 영역에서 모아레 무늬를 제거한다. 즉, Pixel Network는 화소값 영역에서 모아레 무늬를 제거하며, DCT Network는 주파수 영역에서 모아레 무늬를 제거한다. 또한, 모아레 무늬가 곡선이나 줄무늬와 같이 뚜렷하게 구분되는 형태를 가지기 때문에 모아레 영상으로부터 모아레 무늬가 제거된 edge map의 정보를 추출하고 이를 가이드 정보로 사용하면 더욱 효과적으로 모아레 무늬를 제거할 수 있다는 가정 하에 Edge Network를 통해서 영상의 clean edge map을 추출한다. Refinement Network는 Pixel Network 및 DCT Network의 각 결과 영상에 대해서 Edge Network의 clean edge map을 가이드 정보로 사용하여 결과 영상의 품질을 향상시킨다. 마지막으로 향상된 Pixel Network 및 DCT Network의 두 결과 영상을 Fusion Network를 통해 적절하게 결합하여 최종 결과 영상을 생성한다. 컴퓨터 모의실험을 통하여 제안하는 기법이 기존 기법^[3,7,8]에 비해서 모아레 무늬를 효과적으로 제거할 수 있음을 확인한다.

II. 관련 연구

1. 모아레 무늬 제거

최근 화면 촬영 영상 내 모아레 무늬를 제거하기 위한 다양한 기법들이 개발되었다. Yang 등은 모아레의 특징을 주파수 영역에서 희소 행렬을 통해 효과적으로 표현할 수



그림 1. LCDMoiré 데이터셋의 모아레 영상 예시[20]
Fig. 1. Example moiré images in the LCDMoiré dataset[20]

있다는 가정 하에 모델 기반의 모아레 제거 기법을 제안하였다^[9]. 최근에는 딥러닝이 모아레 제거에도 적용되어 우수한 성능을 얻을 수 있음이 확인되었다. 예를 들어, Sun 등은 모아레 무늬와 영상의 콘텐츠 간의 상관관계를 활용하기 위해 다중 스케일 네트워크를 적용하였다^[3]. Cheng 등은 동적 특징 인코딩 모듈을 적용하여 모아레 제거 성능을 더욱 향상시켰다^[4]. He 등은 주파수 분포, 엣지 정보, 모아레 형태의 3가지 속성을 사용하여 모아레 무늬의 다양한 특성을 활용할 수 있는 기법을 개발하였다^[5]. Zheng 등은 주파수 영역에서 모아레 무늬를 모델링하는 네트워크를 개발하였다^[6]. He 등은 전역적인 구조를 가지는 모아레 무늬를 제거하기 위해 기존 기법들 보다 receptive field를 더욱 확장하여 모아레를 제거하였다^[10]. Liu 등은 다양한 크기의 모아레 무늬를 제거하기 위해 멀티스케일 네트워크를 개발하였다^[11]. 하지만, 기존의 접근 방식들은 모두 화소값 영역이나 주파수 영역 중 하나의 영역에서만 모아레를 제거하는 방식을 사용하는 단점이 있다. 본 논문에서는 다중 도메인에서 서로 다른 특성을 활용하여 각각 모아레를 제거한 후 clean edge map을 texture 정보를 효과적으로 유지할 수 있는 가이드 정보로 사용하고 모든 결과 영상을 결합하며 모아레를 제거하는 동시에 영상의 texture를 유지하여 성능을 더욱 향상시키는 기법을 개발한다.

2. 주파수 영역 학습

최근 연구에서 주파수 영역에서의 CNN 기반 영상 복원

기법이 높은 성능을 보일 수 있음이 확인되었다. 예를 들어 Liu 등은 DWT(discrete wavelet transform) 영역에서 압축 아티팩트 및 잡음 제거 등 다양한 영상 복원 기법을 적용할 수 있음을 보였다^[12]. Zheng 등은 DCT 도메인에서 압축 아티팩트를 제거하였으며^[13], 이를 더욱 발전시켰다^[6]. Vien 등은 주파수 도메인과 화소값 도메인에서 입력 영상의 모아레를 각각 제거 후 결과 영상을 결합하여 모아레 제거 성능을 향상시켰다^[8]. Luo 등은 DWT를 이용하여 영상의 해상도를 줄이고 IDWT를 통해 다시 영상의 해상도를 복원하며 정보의 손실 없이 영상을 복원하는 기법을 제안하였다^[14]. Liu 등은 주파수 영역에서 넓은 범위에 퍼져있는 모아레 성분을 제거하면서도 영상 내 고주파 정보를 유지하기 위해 웨이블릿 영역에서 이중 네트워크를 이용하여 모아레를 제거하였다^[15].

III. 제안하는 기법

제안하는 네트워크는 그림 2가 도시하는 것처럼 Pixel Network, Edge Network, DCT Network, Refinement Network의 4가지의 네트워크들로 구성된다. 먼저 Pixel Network와 DCT Network를 이용하여 모아레가 제거된 영상을 획득한다. 두 번째로 Edge Network를 통해 clean edge map을 추출하여 영상의 texture 정보를 효과적으로 유지할 수 있는 가이드 정보를 추출한다. Refinement Network는 Pixel Network 및 DCT Network의 각 결과 영상과 Edge

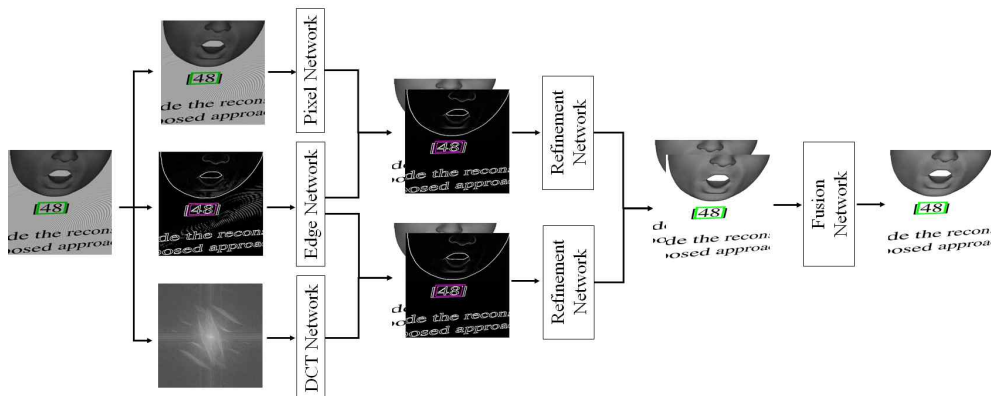


그림 2. 제안하는 전체 네트워크 구조
 Fig. 2. Overview of the proposed demoiréing algorithm

Network의 clean edge map을 가이드 정보로 사용하며 향상된 결과 영상을 생성한다. 마지막으로, 향상된 Pixel Network 및 DCT Network의 두 결과 영상을 Fusion Network를 통해 결합하며 최종 결과 영상을 생성한다.

1. Pixel Network

Pixel Network는 그림 3이 도시하는 것과 같이 입력 영상을 화소값 영역에서 여러 해상도를 가진 branch를 통해 모아래 무늬를 제거한다. 최근 다중 스케일을 이용한 기법이 무늬를 효과적으로 제거한다는 연구 결과에 기반하여^[3,5,6,16], 제안하는 Pixel Network는 화소 영역에서 서로 다른 크기를 가지는 3개의 branch로 구성된다. 입력 영상은 3×3 convolution kernel을 통해 초기 특징맵을 추출한다. 추출된 특징맵은 2×2 convolution kernel을 통해 크기를 줄인다. 각 branch는 제안하는 Multiple receptive field block (MRFB)과 Tone-mapping block (TMB)^[6]으로 구성된다. MRFB는 서로 다른 dilation factor를 통해 convolution의 receptive field를 넓히며, residual dense block (RDB)^[17]을 사용하여 모아래 무늬를 효과적으로 제거한다. Tone mapping block (TMB)은 모아래 영상 생성 모델이 영상의 전체적인 밝기를 저하시키기 때문에 영상의 밝기를 복원하기 위해 사용된다. 각 branch의 마지막 단계에서는 작아진 특징맵을 pixel shuffle^[18]을 통해 해상도를 키우고

그 다음 branch의 입력 영상에 결합한다. 최상위 branch에서는 마지막 convolution을 통해 결과 영상을 생성한다.

제안하는 MRFB는 receptive field를 확장하여 모아래 무늬는 효과적으로 제거할 수 있다는 관찰^[8,16]에 기초하여 그림 4가 도시하는 것과 같이 서로 다른 receptive field 크기를 가지는 3개의 branch로 구성된다. 각 branch의 receptive field를 넓히기 위해 dilation factor (DF)를 통해 커널의 크기가 결정되는 dilated convolution^[19]을 채택했다. 제안하는 MRFB의 각 branch는 서로 다른 $DF = \{1, 2, 3\}$ 을 적용했다. 또한, RDB를 사용하여 입력 영상의 계층적 특징을 모두 활용한다. MRFB는 그림 4가 도시하는 것과 같이 특징맵 추출, 3개의 RDB, 및 특징맵 결합으로 구성된다. 먼저 단일 convolution을 통해 초기 특징맵을 추출하고, 추출된 특징맵은 3개의 RDB에 입력되며, 계층적 특징들이 추출되고 모두 합쳐진다. 3가지 branch의 결과물은 모두 결합되고, 최종적으로 global residual connection을 통해 안정성을 강화한다.

모아래 영상 생성 모델은 영상의 밝기를 감소시킨다^[20]. 밝기 변화를 선형 변환을 이용하여 모델링할 수 있다는 가정 하에, TMB^[6]를 사용하여 전역적인 밝기 차이를 학습하여 밝기 저하를 보상한다. TMB는 그림 5가 도시하는 것과 같이 영상의 전역적인 밝기를 보상하는 전역 branch와 영상의 지역적인 밝기를 보상하는 local branch를 이용하여 모아래 영상과 원본 영상 사이의 밝기 차이를 보상한다.

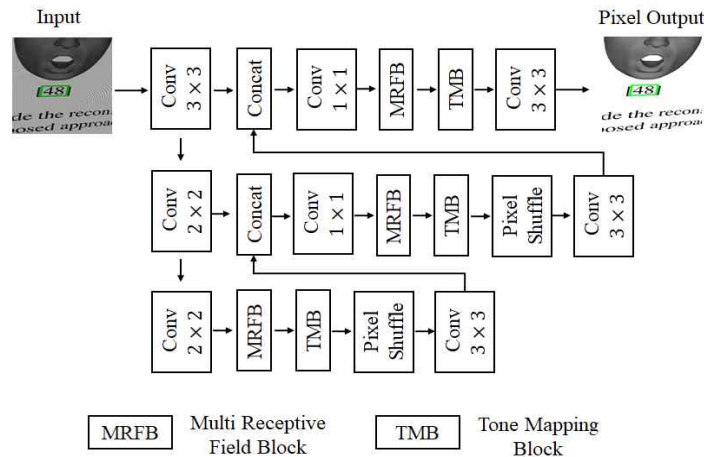


그림 3. Pixel Network의 구조
Fig. 3. Overview of the Pixel Network

Global branch에서는 MRFB를 통해 추출된 특징맵을 stride 1인 3×3 convolution과 adaptive average pooling을 통해 전역 특징을 추출한다. 그리고 ReLU를 포함한 2개의 fully connected (FC) layer와 활성화 함수가 없는 1개의 FC layer를 통해 전역 변환 매개 변수 α 를 생성한다. Local branch에서는 2개의 3×3 convolution을 통해 지역 특징맵을 추출하고, 전역 변환 매개 변수 α 와 지역 특징맵을 곱하여 영상의 전체 색상을 보상한다. 따라서, TMB는 아래와 같이 표현할 수 있다.

$$F_{TMB} = \alpha \times F_{local}. \quad (1)$$

2. DCT Network

영상 내의 texture와 모아레 무늬는 구분이 어렵지만, 주파수 영역에서는 변환 계수 분포가 서로 다른 특징을 가지기 때문에 구분이 가능하다^[5]. 따라서, 주파수 영역에서의 학습을 통해서 모아레 무늬를 효과적으로 제거할 수 있다. 본 연구에서는 Vien 등에 의해서 제안된 DCT Network^[8]을 채택하여 화소 영역에서는 구분할 수 없는 모아레를 주파

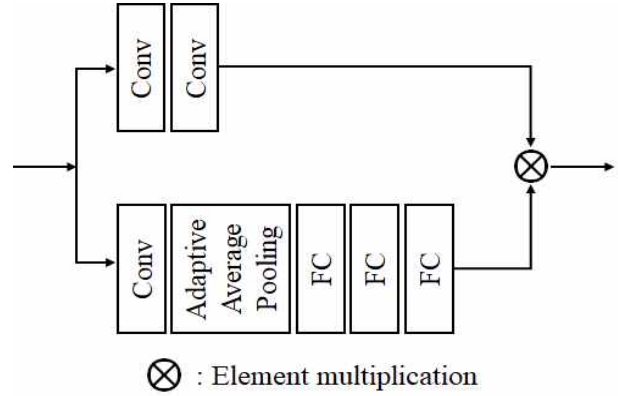


그림 5. TMB의 구조
 Fig. 5. Structure of TMB

수 영역에서 제거한다. 그림 6은 본 연구에서 사용하는 DCT Network를 도시한다. DCT Network는 입력 영상을 DCT를 이용하여 주파수 영역으로 변환하고, 단일 ADB (attention dense block)와 3개의 RADB (residual attention dense block)을 이용한다. ADB와 RADB는 DB (dense block)^[21, 22]과 RADB에 dynamic feature selection을 통해 최근 영상 복원 분야에서 우수한 성능을 보이는 attention

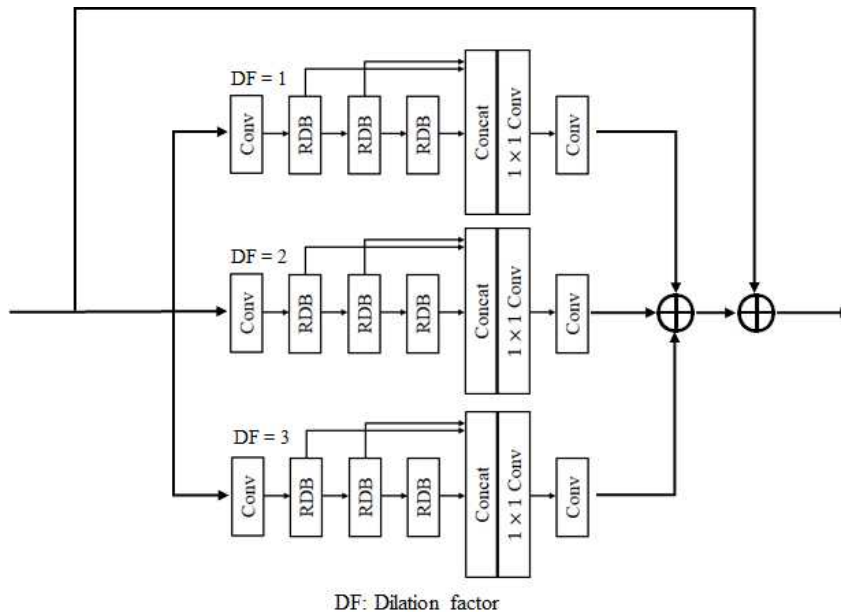


그림 4. MRFB의 구조
 Fig. 4. Structure of MRFB

module인 CBAM (convolutional block attention module)^[23]을 추가한 블록이다. ADB와 RADB를 통해 주파수 영역에서 모아레를 제거하고 제거된 영역의 정보를 효과적으로 복원할 수 있다. 마지막으로 역 이산 코사인 변환(IDCT)을 통해 영상을 화소값 영역으로 변환하여 결과 영상을 생성한다.




그림 6. DCT Network의 구조^[8]
Fig. 6. Overview of the DCT Network^[8]

3. Clean Edge Predictor

모아레 무늬는 곡선이나 줄무늬와 같이 뚜렷하게 구분되는 형태를 가진다. 따라서 모아레 영상으로부터 모아레 무늬가 제거된 clean edge map의 정보를 추출하고 이를 가이드 정보로 사용하면 더욱 효과적으로 모아레 무늬를 제거할 수 있다. 그림 7이 도시하는 것과 같이 Edge Network는 입력 영상으로부터 clean edge map을 예측한다. Edge Network는 먼저 소벨 연산자를 사용하여 초기 edge map을 추출하며, 3개의 branch로 구성된 다중 스케일 네트워크를 통해 최종 edge map을 추출한다. 각 branch는 U-Net^[24] 및 non-local block^[25]으로 구성되며 3개의 edge map의 평균을 구해서 최종 clean edge map으로 출력한다.

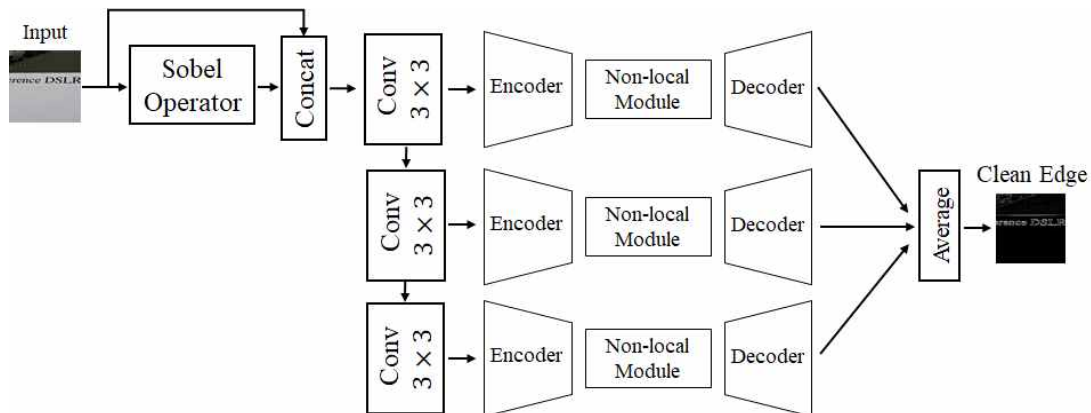


그림 7. Edge Network의 구조
Fig. 7. Overview of the Edge Network

4. Refinement Network

Pixel Network와 DCT Network는 서로 다른 영역에서 모아레 영상을 제거하기 때문에 각각의 결과 영상은 최종 결과 영상을 보완하는 후보들로 사용할 수 있다. 하지만 Pixel Network와 DCT Network는 강한 모아레 무늬를 완벽하게 제거하지 못한다. 따라서, 본 연구에서는 그림 2가 도시하는 것과 같이 Edge Network의 결과물인 clean edge map을 texture 정보를 효과적으로 유지할 수 있는 가이드 정보로 사용하여 Pixel Network 및 DCT Network의 각 결과 영상의 품질을 향상시킨다. Refinement Network는 모아레가 제거된 영상과 clean edge map을 입력으로 받아서 향상된 결과 영상을 생성한다. 또한, Refinement Network는 그림 1에서 도시하는 것과 같이 향상된 Pixel Network와 DCT Network의 두 결과 영상을 결합하여 최종 결과 영상을 생성하는 Fusion Network로도 사용된다. 그림 8은 본 연구에서 개발한 Refinement Network의 구조를 도시한다.

5. Training

제안하는 네트워크는 Pixel Network, DCT Network, Edge Network, Refinement Network의 총 4가지의 네트워크로 구성된다. GPU의 메모리 성능 한계로 전체 네트워크를 End-to-End 방식으로 학습할 수 없기 때문에, 각 네트워크를 독립적으로 학습하였다. 따라서 먼저 Pixel Network,




그림 8. Refinement Network의 구조
Fig. 8. Architecture of the Refinement Network

DCT Network, Edge Network를 독립적으로 학습하고, 학습 완료된 네트워크를 이용하여 Refinement Network를 학습한다. 본 연구에서는 모든 네트워크 학습에 AdamW^[26]를 이용하였으며, $\beta_1 = 0.9$ 및 $\beta_2 = 0.99$ 의 학습률을 사용하였다. 학습률은 10^{-3} 으로 시작하여 50 epoch마다 0.1의 비율로 감소시켰다. 또한, 입력 영상을 무작위로 128×128 크기로 crop하여 batch size 16으로 네트워크를 학습시켰다. 128×128 크기의 학습이 완료되면 256×256 으로 크기를 증가시켜 fine-tuning 하였다. Fine-tuning에서는 학습률을 10^{-5} 로 설정하였고 batch size는 8로 설정하였다.

Pixel Network와 Refinement Network를 학습시키는 pixel loss L_p 는 아래와 같이 L_1 loss와 ASL (Advanced Sobel Loss)^[6]의 합으로 정의하였다.

$$L_p(\hat{I}, I_{gt}) = \|\hat{I} - I_{gt}\|_1 + \mu \sum_{k=1}^4 \|F_k(\hat{I}) - F_k(I_{gt})\|_1. \quad (2)$$

여기에서 μ 는 L_1 loss와 ASL 사이의 상대적인 중요도를 나타내며, $F_k(\cdot)$ 는 Sobel 필터의 수평, 수직, 대각선 필터 중 k 번째 필터로 얻어진 edge map을 나타낸다.

DCT Network를 학습시키는 DCT loss L_{DCT} 는 아래와 같이 DCT domain에서 ground truth와 모아레 영상을 L_1 norm으로 비교한다.

$$L_{DCT}(\hat{I}, I_{gt}) = \|\text{DCT}(\hat{I}) - \text{DCT}(I_{gt})\|_1. \quad (3)$$

여기에서 $\text{DCT}(\cdot)$ 는 DCT 변환을 나타낸다.

Edge Network를 학습시키는 L_e 는 아래와 같이 추정되는 edge map인 \hat{E} 와 ground truth의 edge map E_{gt} 를 L_1

norm으로 비교한다.

$$L_e(\hat{E}, E_{gt}) = \|\hat{E} - E_{gt}\|_1. \quad (4)$$

IV. 실험결과

본 논문에서는 LCDMoire 데이터셋^[20]을 이용하여 제안하는 모아레 제거 기법의 성능을 평가한다. LCDMoire 데이터셋은 총 10,200장으로 구성되어 있으며, 10,000장의 학습 영상, 100장의 검증 영상, 100장의 테스트 영상으로 구성된다. LCDMoire 데이터셋의 테스트 영상의 ground-truth가 제공되지 않기 때문에 검증 영상을 이용하여 모의 실험을 진행하였다. CAS-CNN^[7], DMCNN^[3], DDCNN^[8]과 비교하며 모아레 무늬 제거 성능을 평가한다.

그림 9는 LCDMoire 데이터셋의 검증 영상에 대한 각 알고리즘의 모아레 제거 결과 영상을 비교한다. 그림 9(c)-(d)의 CAS-CNN 및 DMCNN은 결과 영상에 모아레 무늬가 남아있을 뿐만 아니라 영상의 밝기를 효과적으로 복원하지 못하는 것을 확인할 수 있다. 또한 그림 9(e)의 DDCNN은 저하된 밝기는 효과적으로 보상할 수 있으나, 모아레 무늬를 효과적으로 제거하지 못하여 마지막 행의 영상에서는 녹색 영역에 검은 얼룩이 남아 있는 것을 확인할 수 있다. 반면 제안하는 기법은 강한 모아레 무늬를 효과적으로 제거하면서도 저하된 영상의 밝기를 복원하는 것을 확인할 수 있다. 이는 제안하는 기법은 서로 다른 특징을 가지는 다중 도메인에서의 학습을 통하여 모아레의 다양한 속성을 활용할 수 있기 때문이다.

모아레 제거 성능을 주관적 평가뿐만 아니라 PSNR 및 SSIM (structural similarity index)^[27]을 이용한 객관적인 평가를 진행하였다. 표 1은 LCDMoire 데이터셋의 모든 검증 영상을 이용한 평균 PSNR 및 SSIM 결과를 보여준다. 제안하는 기법이 기존의 기법들과 비교하여 가장 높은 PSNR 및 SSIM 성능을 보임을 확인할 수 있다. 특히, 제안하는 기법은 CAS-CNN, DMCNN, DDCNN과 비교하여 각각 4.53, 5.24, 2.67dB 높은 PSNR 결과를 제공하며, SSIM에 대해서도 가장 높은 성능을 보임을 확인할 수 있다.

마지막으로, 본 연구에서 제안하는 다중 네트워크에서

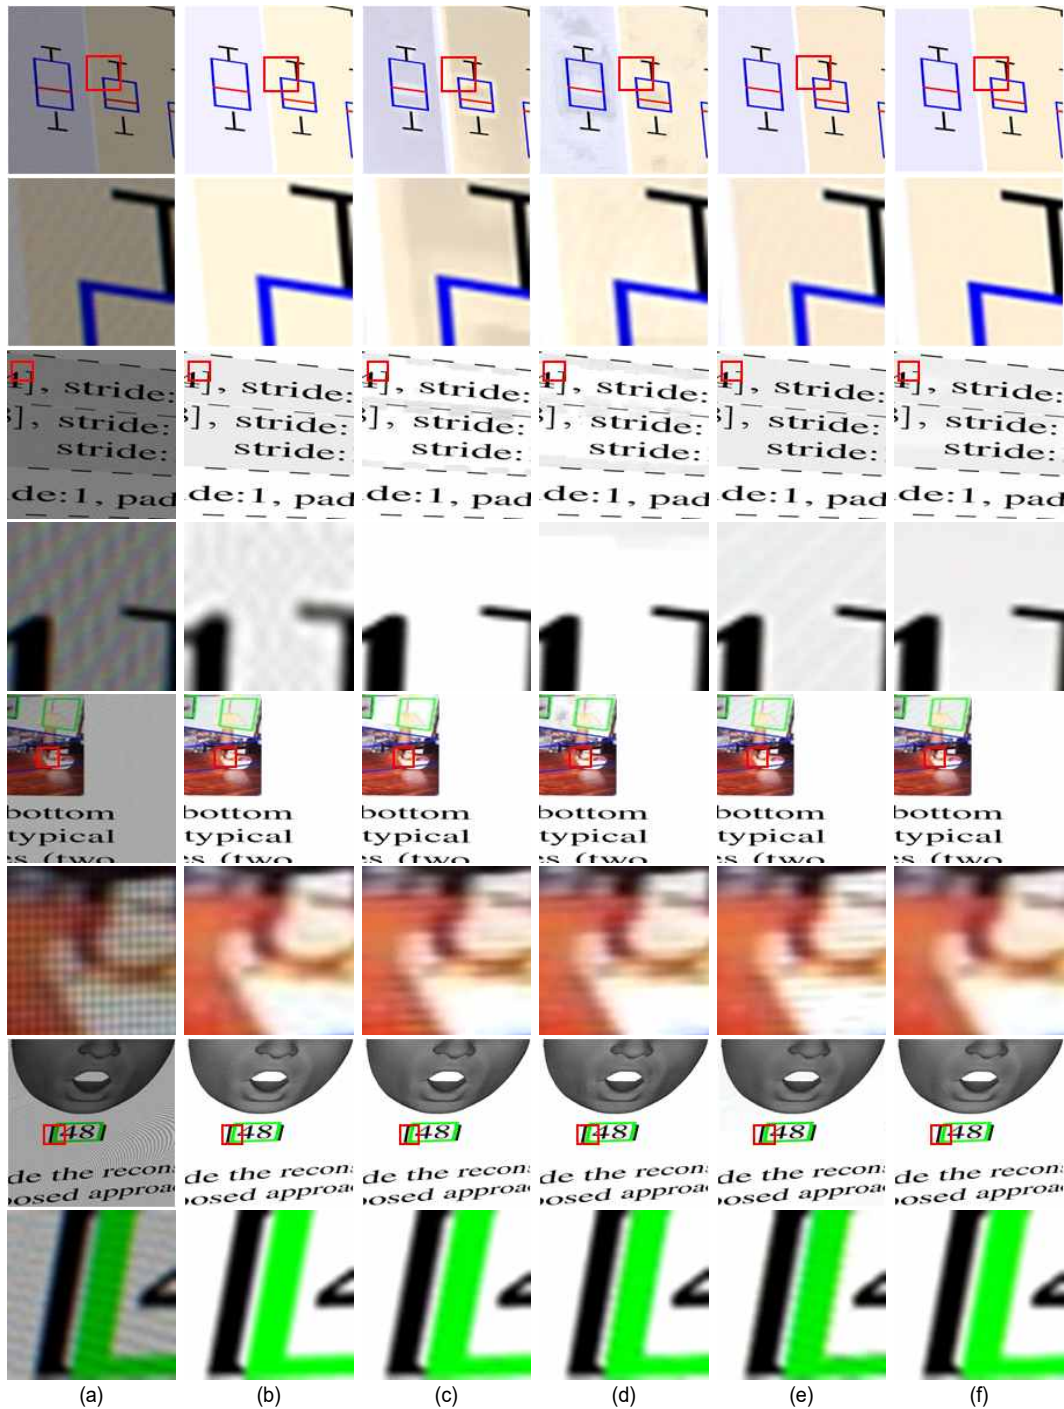


그림 9. 모아레 제거 결과 영상. 2, 4, 6, 8행은 빨간색 상자를 확대한 영상을 나타낸다.

(a) 모아레 영상, (b) ground-truth, (c) CAS-CNN [7], (d) DMCNN [3], (e) DDCNN [8], (f) 제안하는 기법.

Fig. 9. Demoiréing results for the validation set. (a) Moiré image, (b) ground-truth, and outputs of (c) CAS-CNN [7], (d) DMCNN [3], (e) DDCNN [8], and (f) the proposed algorithm

각 서브 네트워크 별 기여도를 분석하기 위한 ablation study를 진행하였다. 표 2는 본 연구에서 진행한 각 네트워크 별 효과를 비교한다. 먼저 Pixel Network 및 DCT Network만을 이용하면 39.79 및 37.00dB의 PSNR 결과를 얻는다. Edge Network를 이용하여 얻은 clean edge map을 가이드 정보로 사용하는 Refinement Network를 적용하면, 각각 0.85 및 2.78dB의 PSNR 성능 향상을 얻을 수 있다. 마지막으로, Refinement Network을 이용하여 향상된 두 결과 영상을 Fusion Network를 이용하여 적응적으로 결합하면 더욱 향상된 PSNR 성능을 얻을 수 있음을 확인할 수 있다. 이를 통해 본 연구에서 제안하는 기법이 다중 네트워크 학습과 clean edge map을 사용하며 영상 내 모아레 무늬를 효과적으로 제거할 수 있음을 알 수 있다.

표 1. CAS-CNN [7], DMCNN [3], DDCNN [8], 및 제안하는 기법의 정량적 비교.

Table 1. Quantitative comparison of CAS-CNN [7], DMCNN [3], DDCNN [8], and the proposed algorithm

	CAS-CNN	DMCNN	DDCNN	Proposed
PSNR	36.18	35.47	38.04	40.71
SSIM	0.983	0.973	0.978	0.983

표 2. 서로 다른 네트워크의 효과 분석

Table 2. Impacts of different combinations of networks

	PSNR
Pixel Network	39.79
DCT Network	37.00
Pixel Network + Edge Network	40.64
DCT Network + Edge Network	39.78
Proposed	40.71

V. 결론

본 논문은 다중 도메인 학습을 이용한 화면 촬영 영상 내 모아레 무늬를 효과적으로 제거하는 기법을 제안하였다. 제안하는 네트워크는 Pixel Network, Edge Network, DCT Network, Refinement Network로 구성된다. Pixel Network와 DCT Network에서는 각각 화소 영역과 주파수 영역에서 영상의 서로 다른 특성을 이용하여 모아레를 제거한다.

Edge Network는 모아레 영상을 입력받아 모아레가 제거된 clean edge map을 추정한다. 마지막으로 Refinement Network은 Edge Network의 clean edge map을 가이드 정보로 사용하여 Pixel Network 및 DCT Network의 각 결과 영상을 향상시키고, 향상된 두 결과 영상을 Fusion Network를 통해 적응적으로 결합하여 최종 결과 영상을 생성한다. LCDMoire 데이터셋을 이용한 모의실험을 통해서 제안하는 기법이 기존의 기법들에 비해서 모아레 무늬를 효과적으로 제거할 수 있음을 확인한다.

참고 문헌 (References)

- [1] M. Schöberl, W. Schnurrer, A. Oberdörster, S. Fössel, and A. Kaup, "Dimensioning of optical birefringent anti-alias filters for digital cameras," in *Proceeding of IEEE International Conference on Image Processing*, Sep. 2010.
- [2] I. Pekkucuksen and Y. Altunbasak, "Multiscale gradients based color filter array interpolation," *IEEE Transactions Image Processing*, vol. 22, no. 1, pp. 157-165, Jan. 2013.
- [3] Y. Sun, Y. Yu, and W. Wang, "Moiré photo restoration using multi-resolution convolutional neural networks," *IEEE Transactions Image Processing*, vol. 27, no. 8, pp. 4160-4172, Aug. 2018.
- [4] X. Cheng, Z. Fu, and J. Yang, "Multi-scale dynamic feature encoding network for image demoiréing," in *Proceedings of IEEE/CVF International Conference on Computer Vision Workshops*, Oct. 2019, pp. 3486 - 3493.
- [5] B. He, C. Wang, B. Shi, and L. Duan, "Mop moiré patterns using MopNet," in *Proceedings of IEEE International Conference on Computer Vision*, Oct./Nov. 2019, pp. 2424-2432.
- [6] B. Zheng, S. Yuan, G. Slabaugh, and A. Leonardis, "Image demoiréing with learnable bandpass filters," in *Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Jun. 2020, pp. 3636 - 3645.
- [7] L. Cavigelli, P. Hager, and L. Benini, "CAS-CNN: A deep convolutional neural network for image compression artifact suppression," in *Proceedings of International Joint Conference on Neural Networks*, May 2017, pp. 752 - 759.
- [8] A. G. Vien, H. Park, and C. Lee, "Dual-domain deep convolutional neural networks for image demoiréing," in *Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, Jun. 2020, pp. 1934 - 1942.
- [9] J. Yang, F. Liu, H. Yue, X. Fu, C. Hou, and F. Wu, "Textured image demoiréing via signal decomposition and guided filtering," *IEEE Transactions Image Processing*, vol. 26, no. 7, pp. 3528 - 3541, Jul. 2017.
- [10] B. He, C. Wang, B. Shi, and L.-Y. Duan, "FHDe2Net: Full high definition demoiréing network." in *Proceedings of European Conference*

- on Computer Vision, Sep. 2020, pp. 713-729.
- [11] B. Liu, X. Shu, and X. Wu, "Demoireing of camera-captured screen images using deep convolutional neural network," arXiv preprint arXiv:1804.03809, 2018.
- [12] P. Liu, H. Zhang, K. Zhang, L. Lin, and W. Zuo, "Multi-level wavelet CNN for image restoration," in Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Jun. 2018, pp. 886 - 895.
- [13] B. Zheng, Y. Chen, X. Tian, F. Zhou, and X. Liu, "Implicit dual-domain convolutional network for robust color image compression artifact reduction," IEEE Transactions on Circuits and Systems for Video Technology, vol. 30, no. 11, pp. 3982-3994, Nov. 2020.
- [14] X. Luo, J. Zhang, M. Hong, Y. Qu, Y. Xie, and C. Li, "Deep wavelet network with domain adaptation for single image demoireing," in Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Jun. 2020, pp. 1687-1694.
- [15] L. Liu, J. Liu, S. Yuan, G. Slabaugh, A. Leonardis, W. Zhou, and Q. Tian, "Wavelet-based dual-branch network for image demoireing," in Proceedings of European Conference on Computer Vision, Aug. 2020, pp. 86-102.
- [16] X. Cheng, Z. Fu, and J. Yang, "Multi-scale dynamic feature encoding network for image demoireing," in Proceedings of IEEE/CVF International Conference on Computer Vision Workshops, Oct. 2019, pp. 3486 - 3493.
- [17] Y. Zhang, Y. Tian, Y. Kong, B. Zhong, and Y. Fu, "Residual dense network for image super-resolution," in Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition, Jun. 2018, pp. 2472-2481.
- [18] W. Shi, J. Caballero, F. Huszar, J. Totz, A. P. Aitken, R. Bishop, D. Rueckert, and Z. Wang, "Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network," in Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Jun. 2016, pp. 1874 - 1883.
- [19] F. Yu and V. Koltun, "Multi-scale context aggregation by dilated convolutions," in Proceedings of International Conference Learning Representations, May 2016.
- [20] S. Yuan, R. Timofte, G. Slabaugh, and A. Leonardis, "AIM 2019 challenge on image demoireing: Dataset and study," in Proceedings of IEEE/CVF International Conference on Computer Vision Workshops, Oct. 2019, pp. 3526-3533.
- [21] G. Huang, Z. Liu, L. V. D. Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Jul. 2017, pp. 2261-2269.
- [22] T. Tong, G. Li, X. Liu, and Q. Gao, "Image super-resolution using dense skip connections," in Proceedings of IEEE International Conference on Computer Vision, Jul. 2017, pp. 4809-4817.
- [23] S. Woo, J. Park, J.-Y. Lee, and I. S. Kweon, "CBAM: Convolutional block attention module," in Proceedings of European Conference on Computer Vision, Sep. 2018, pp. 3-19.
- [24] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional networks for biomedical image segmentation," in Proceedings of Medical Image Computing and Computer-Assisted Intervention, Nov. 2015, pp. 234.241.
- [25] X. Wang, R. Girshick, A. Gupta, and K. He, "Non-local neural networks," in Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Jul. 2018, pp. 7794-7803.
- [26] I. Loshchilov and F. Hutter, "Decoupled weight decay regularization. in Proceedings in International Conference on Learning Representations, 2018.
- [27] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: From error visibility to structural similarity," IEEE Transactions Image Processing, vol. 13, no. 4, pp. 600 - 612, Apr. 2004.


저 자 소 개



박 현 국

- 2019년 : 동국대학교 멀티미디어공학과 공학사
- 2020년 ~ 현재 : 동국대학교 멀티미디어공학과 석사과정
- ORCID : <https://orcid.org/0000-0003-4993-8553>
- 주관심분야 : 계산사진학, 영상처리, 컴퓨터비전

저 자 소 개



비엔지아안

- 2015년 : University of Science, Vietnam, Bachelor of Computer Science
- 2016년 ~ 2019년 : 부경대학교 컴퓨터공학과 공학석사
- 2019년 ~ 현재 : 동국대학교 멀티미디어공학과 박사과정
- ORCID : <https://orcid.org/0000-0003-0067-0285>
- 주관심분야 : 계산사진학, 영상처리, 컴퓨터비전



이 철

- 2003년 : 고려대학교 전기전자전파공학부 공학사
- 2008년 : 고려대학교 전자전기공학과 공학석사
- 2013년 : 고려대학교 전자전기공학과 공학박사
- 2002년 ~ 2006년 : ㈜바이오스페이스 (현 ㈜인바디)
- 2013년 ~ 2014년 : Postdoctoral Scholar, Pennsylvania State University
- 2014년 ~ 2015년 : Research Scientist, The University of Hong Kong
- 2015년 ~ 2019년 : 부경대학교 컴퓨터공학과 조교수
- 2019년 ~ 현재 : 동국대학교 멀티미디어공학과 조교수
- ORCID : <https://orcid.org/0000-0001-9329-7365>
- 주관심분야 : 영상처리, 계산사진학, 컴퓨터비전