

Demoire

김 정 현

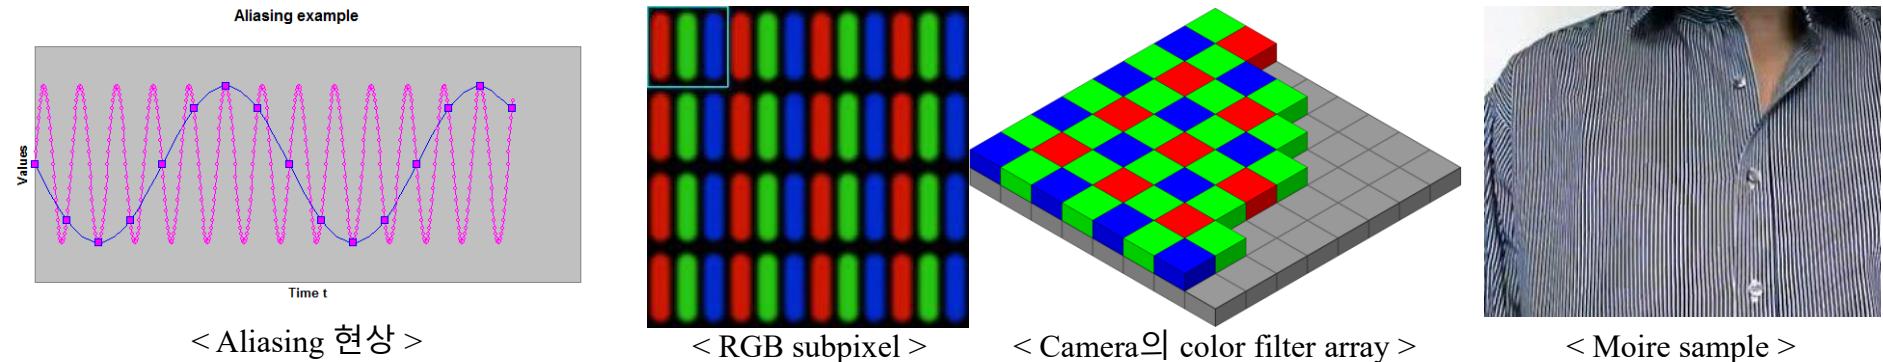
*Vision and Display Systems Lab.
Sogang University*

Outline

- Introduction
- Method
 - DMCNN
 - MopNet
 - FHDe²Net
 - MBCNN, MBCNN+
- Summary

Introduction

- Moire
 - 카메라로 주기적인 규칙이 있는 물체를 촬영하면 artifact, noise가 생김
 - 피사체의 주파수와 카메라 image sensor의 주파수 차이로 인해 Aliasing 현상이 발생
- Aliasing (위신호 현상)
 - Aliasing: 신호 처리에서 sampling을 할 때 각기 다른 신호를 구별해내지 못하는 효과
 - Sampling 주파수가 2배 이상이어야 aliasing현상을 방지



Introduction

- Moire

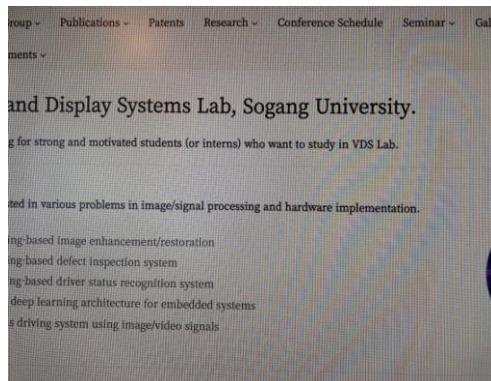
- 모니터를 촬영할때 주로 발생

- 혹은 줄무늬 옷, 방충망을 피사체로 놓을때도 Moire가 생김

- Image 품질을 저하시킴

- 촬영시 전처리로 Moire를 없애는 방법은 성능이 미비 > 사용되지 않음

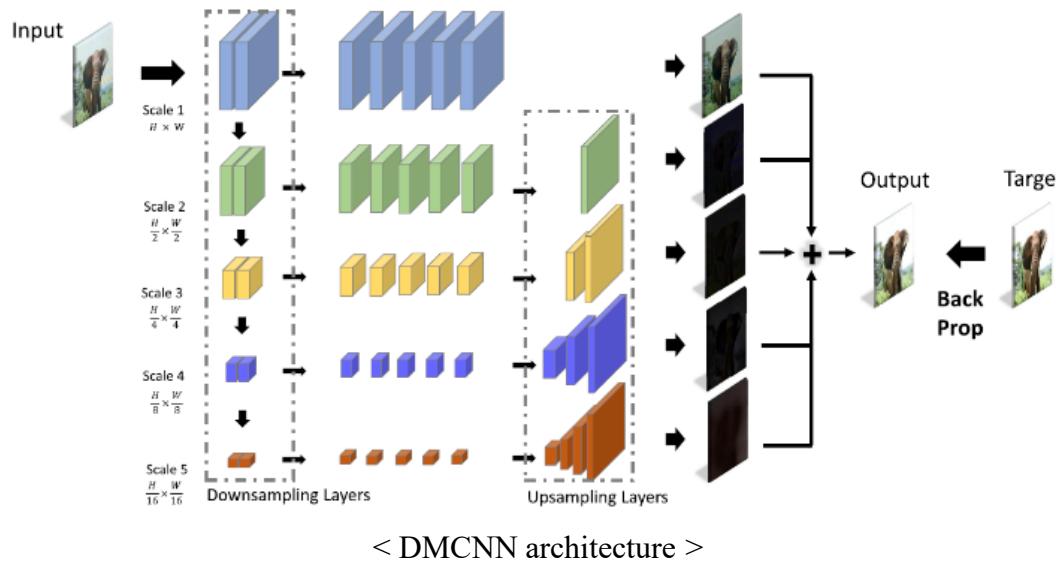
- Demoire 과정은 전처리가 아닌 후처리 위주로 진행



< Moire 예시 >

Method

- DMCNN*
 - 처음으로 Demoire task에 deep learning을 적용한 network
 - Convolution 과 transpose convolution layer로만 구성됨
 - 5개의 multi scale: kernel에 맞는 Moire의 주파수를 제거하기 위함
 - ImageNet을 기반으로 한 최초의 moire dataset을 생성, 많은 논문들의 dataset으로 사용됨



Method

- MopNet*

- Moire를 3가지 측면으로 분석 및 분류

- 주파수 분포의 측면, RGB channel 별 edge 정보, Moire의 외형

- 주파수 분포의 측면 (Multi-scale Aggregation)

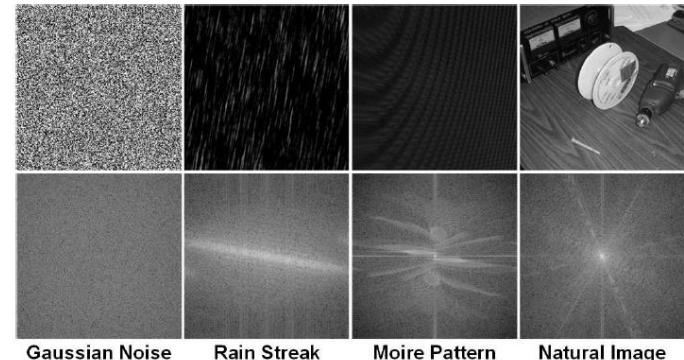
- Moire는 주파수 영역에서 광범위하게 분포됨

Moire 패턴의 스펙트럼은 다양한 방향으로의 변화가 있으므로, 주파수 영역에서의 속성 분석이 필요

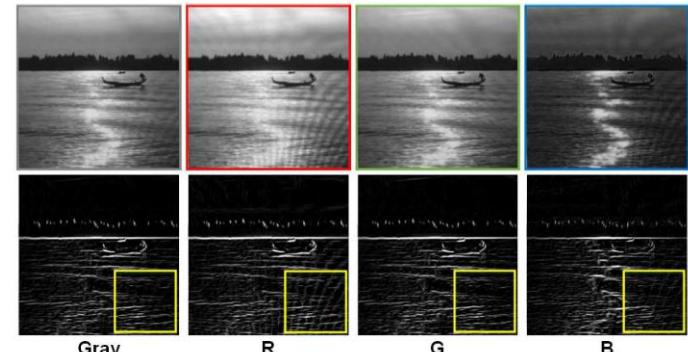
- RGB channel 별 edge 정보 (Channel-wise Target Edge Predictor)

- Moire의 edge는 channel별로 다름, G channel에서 Moire가 가장 약함

- G channel의 Moire를 제거한 edge 정보를 다른 channel의 Moire 제거에 사용



< Image의 종류별 frequency domain >



< Channel에 따른 Moire 강도의 차이 >

Method

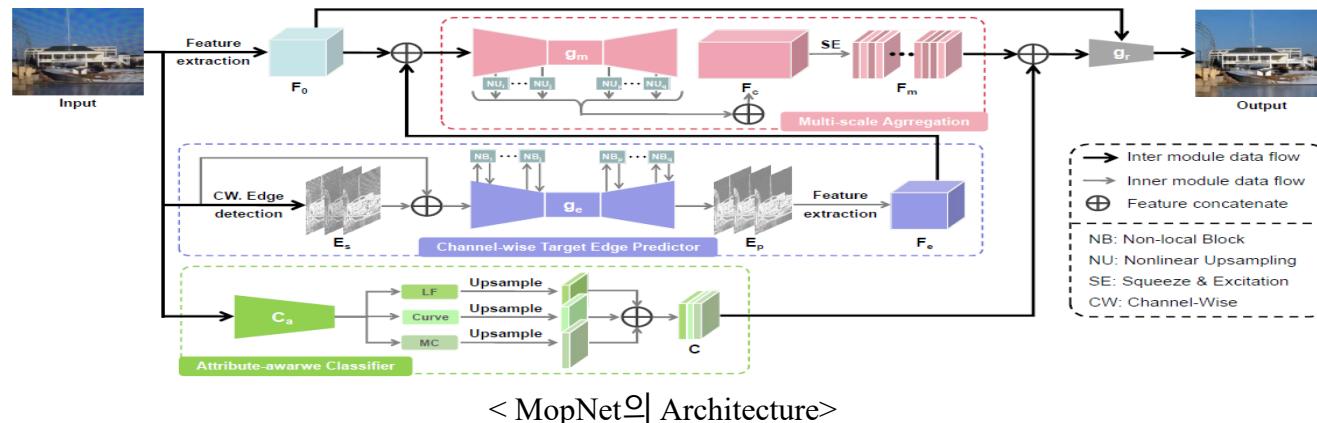
- MopNet*

- Moire의 외형측면 (Attribute aware Classifier)

- Frequency, shape, color의 3가지 범주에서 분류
 - 다양한 Moire의 종류를 classification을 통해 종류에 맞게 Demoire가 가능
 - Over smoothing 방지, color restoration (tone mapping)

- Limitations

- 불규칙한 background는 Moire와 배경을 구분하지 못함



Method

- FHDe²Net*
 - 기존의 dataset의 최대 size는 1024×1024
 - FHD image에서 생긴 Moire를 제거하는 network의 부재
 - 기존 방법들은 size가 작고 crop 한 image를 training
 - FHD image에서의 Moire에 대한 학습이 안 되어있음
 - Moire의 제거와 background texture의 유지 2가지 branch로 진행
 - Global to local cascaded removal branch : Moire 제거 기능
 - frequency based high-resolution content separation branch: Text의 유지 기능

Dataset	Resolution	Amount	Content	Real
TIP 18*	384×384 ~ 700×700	135,000	ImageNet	O
AIM 19**	1024×1024	10,200	Documents only	X
FHDMI	1920×1080	12,000	Films, sports, etc	O

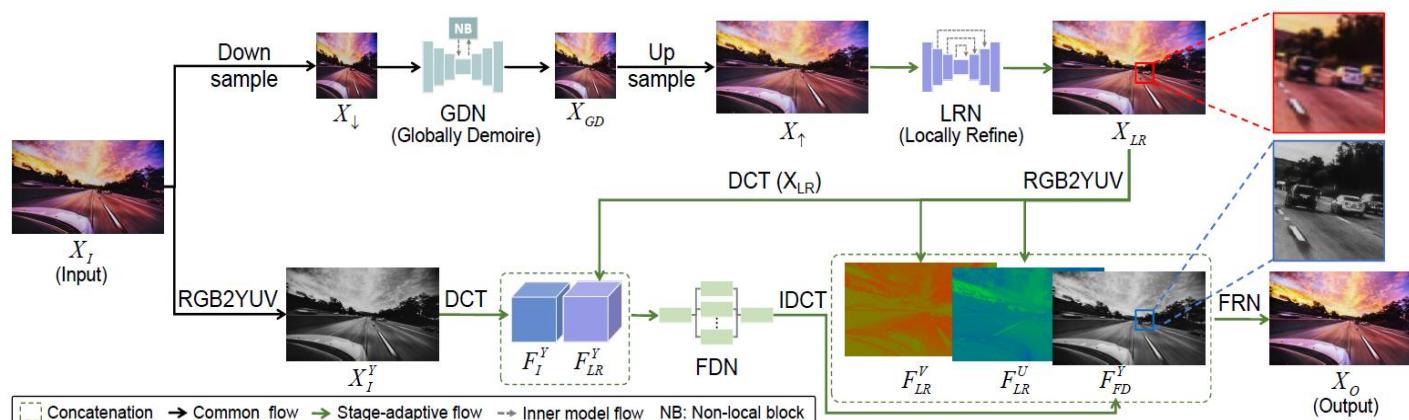
Method

- FHDe²Net*

- Global to local cascaded removal branch 은 크게 global moire, local moire 제거로 나뉨

- Global moire 제거 (FDN) : input을 down sampling 후, auto encoder에 입력함. receptive field 100 > 400, large-scale moire 제거를 위해 nonlocal block* 을 추가

- Local moire 제거 (LRN) 를 위해 local enhancement strategy*를 사용

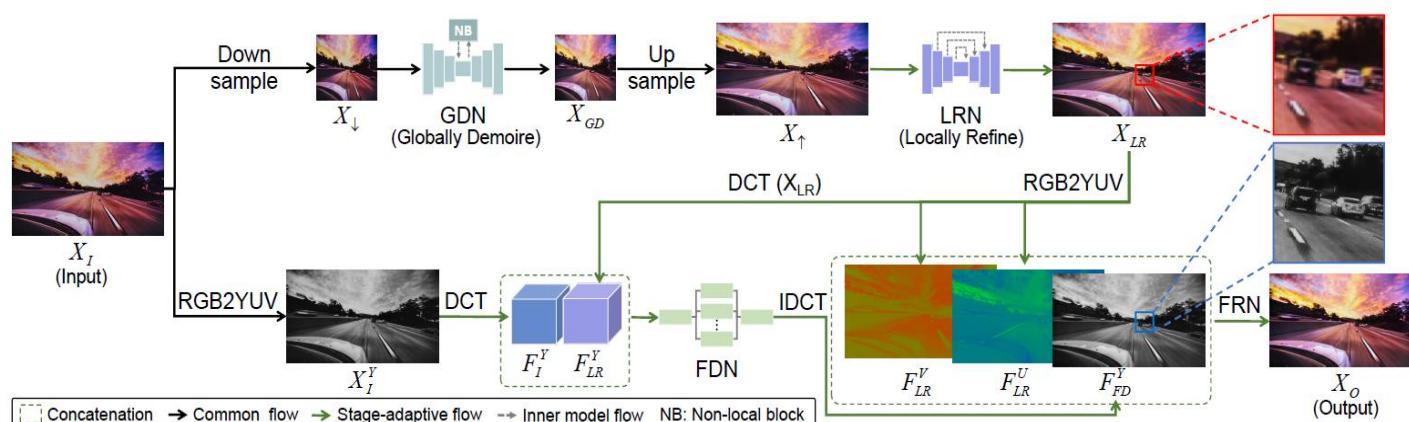


< FHDe²Net architecture >

Method

- FHDe²Net*

- Frequency based high-resolution content separation branch 은 background의 detail 을 유지
 - Moire를 없앤 image의 DCT, input image의 DCT를 concat
 - Background와 moire의 구분을 위해 channel attention을 도입 (SE block)
- Demoire된 image의 UV, background의 detail을 남긴 Y를 합쳐서 RGB 변환



< FHDe²Net architecture >

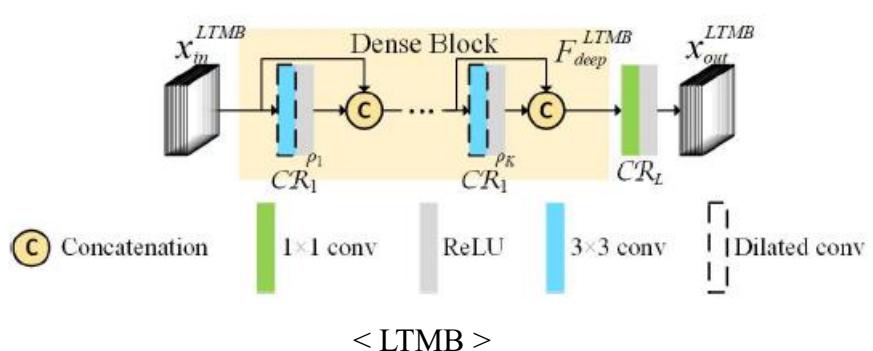
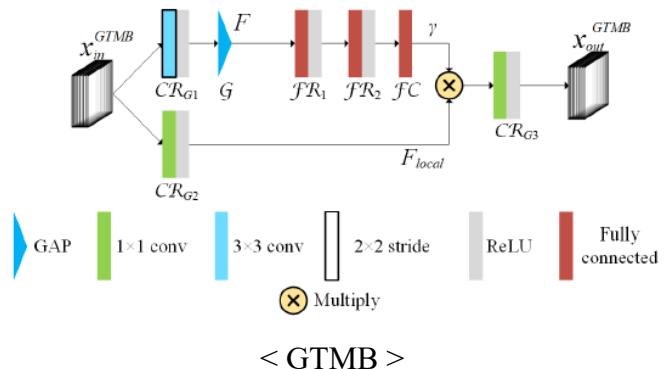
Method

- MBCN*

- Moire 영상을 휘도복원과 Moire pattern의 제거로 분리

- 휘도 복원: tone mapping

- 카메라로 촬영하는 과정에서 color degradation이 있음
 - 이를 복원해주기 위해 GTMB (Global Tone Mapping Block) 와 LTMB (Local Tone Mapping Block) 을 구성
 - GTMB: global feature F 를 추출, F 로 deep global feature γ 를 추출, local feature 추출
↳ Global color shift와 color artifact 방지의 효과가 있음
 - LTMB: fine grained tone mapping의 역할



Method

- MBCNN*

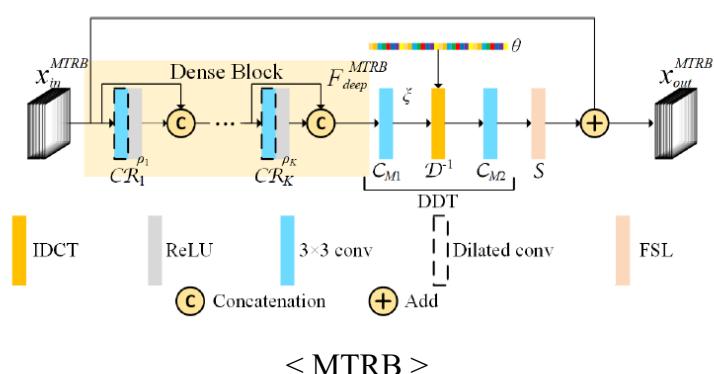
- Moire pattern의 제거: MTRB (Moire Texture Removal Block)

- Moire의 DCT변환을 FS_{fij}^{si} 라고 가정

- Implicit DCT** 를 통해서 FS_{fij}^{si} 를 convolution 으로 ξ^{si} 를 나타낼 수 있음

- ξ^{si} 를 역변환 하는 과정도 convolution으로 나타낼 수 있음

- Frequency별 비중을 두기 위해 θ^{si} 를 곱함



$$N_{moire} = \sum_i \sum_j D^{-1}(D(N_{fij}^{si})) = \sum_i \sum_j D^{-1}(FS_{fij}^{si})$$

$$C(N_p) = \sum_i C(D^{-1}(\theta^{si} \cdot \xi^{si}))$$

$$I_{moire} = \psi(I_{clean}) + N_{moire}$$

< Moire의 모델링 >

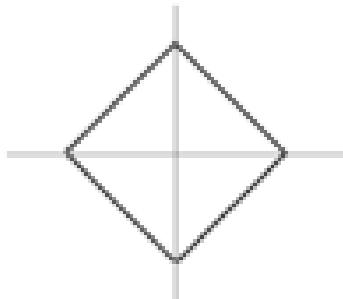
Method

- MBCNN*

- L2 loss는 structural information 을 손상시킴
- Moire artifact는 point-wise loss로는 제거할 수 없음
 - Structural artifact이기 때문
- Sobel loss의 방향성은 2가지이기 때문에 structural information의 활용이 부족함
 - Advanced sobel loss : diagonal 방향을 추가 해서 4가지 방향성을 고려

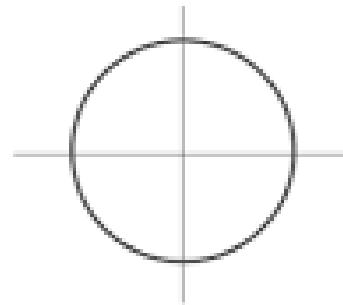
L1 (Manhattan) distance

$$d_1(I_1, I_2) = \sum_p |I_1^p - I_2^p|$$



L2 (Euclidean) distance

$$d_2(I_1, I_2) = \sqrt{\sum_p (I_1^p - I_2^p)^2}$$



Method

- MBCNN*

- Ablation study

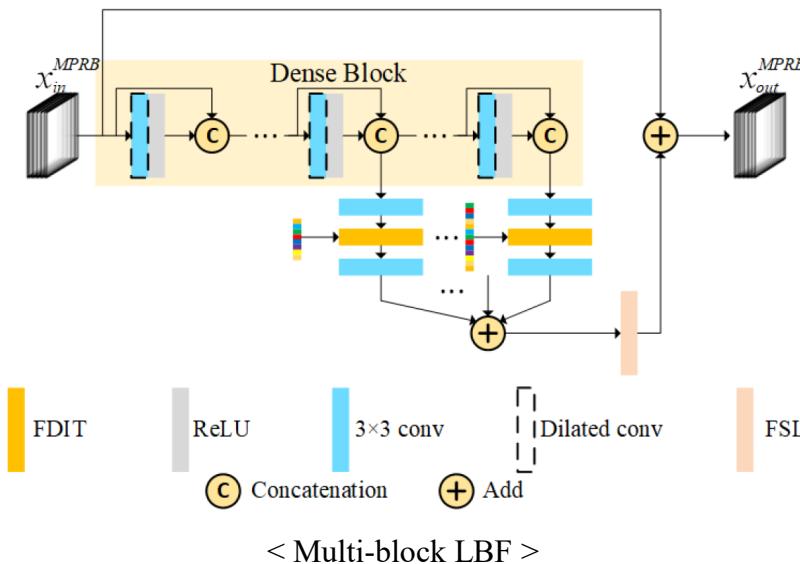
- DCT transform과 learnable weight의 효과를 보기위해 실험 진행
 - DCT를 추가 한 것은 0.18dB의 상승
 - Weight를 learnable하게 만든것은 0.95dB의 상승
 - DCT transform은 1.13dB의 상승을 도출

Model	W/O DCT transform	W/O weight	MBCNN
PSNR/SSIM	42.91/0.9932	43.09/0.9936	44.04/0.9948



Method

- MBCNN+*
 - Multi-block의 사용, transform의 비교, loss의 변화 (dialation ASL)
 - Multi-block-size LBF (Learnable bandpass filter)
 - 하나의 weight θ^{s_i} 특정한 frequency에 mathing이 되었음
 - 여러 weight 를 만들어서 여러 frequency에 matching이 될수 있게 함



Method

- MBCNN+*

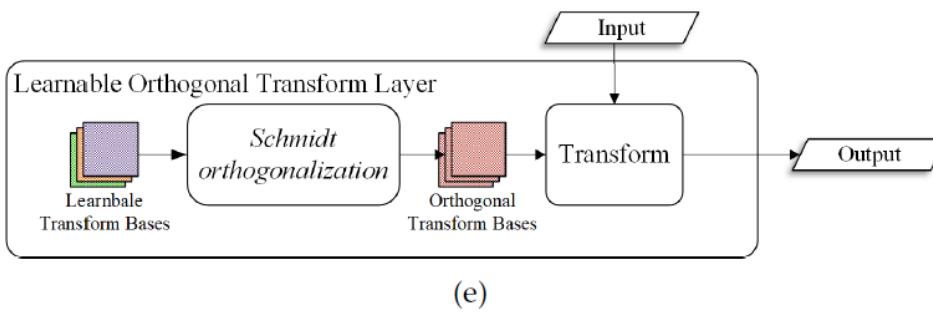
- Frequency Domain Transform (FDT) 의 비교

- 전 논문에서는 DCT만 사용함, DCT가 아닌 다른 transform의 효용성을 검증하기 위해 실험

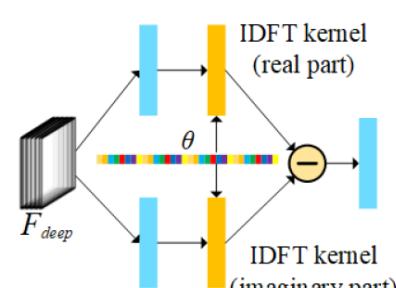
- DCT, Discrete Wavelet Transform (DWT), Discrete Fourier Transform (DFT), Learnable Non-linear Transform (LNT), Learnable Orthogonal Transform (LOT)

- LOT: orthogonality constraint로 transformation loss 를 없앰

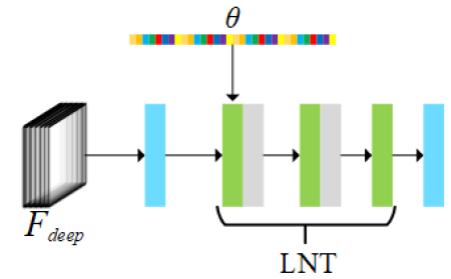
- LNT 는 conv 뒤에 ReLU를 추가해서 Non-Linear하게 만듬



< Learnable Orthogonal Transform >



< Fourier Transform >



< Learnable Nonlinear Transform >

Method

- MBCNN+*

- Frequency Domain Transform의 비교

- 기존의 DCT가 성능이 가장 높음

- LOT, LOT는 transform base 와 corresponding 을 동시에 학습해야 함.

- DFT는 real + imaginary, DCT는 real만, DCT는 DFT보다 energy compaction이 높기 때문에 DCT가 높은 것으로 예상

< Transform 별 비교 >

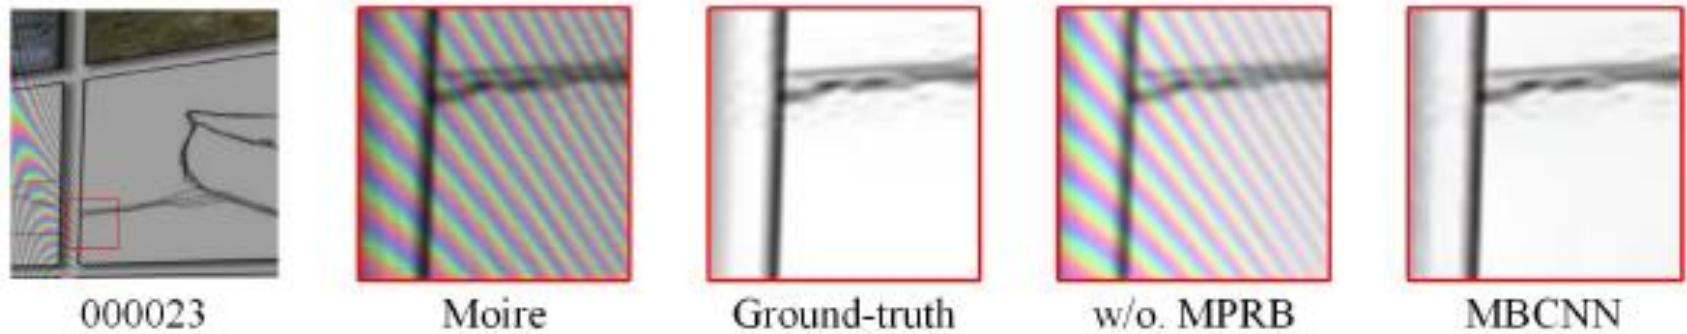
Transform	IDWT	IDCT	IDFT	LNT	LOT
PSNR	44.26	45.08	44.69	43.06	42.69
SSIM	0.9963	0.9967	0.9965	0.9898	0.9953

Method

- MBCNN+*

- Ablation Study: MPRB

- MPRB가 없어도 tone mapping은 잘 됨, color degradation 이 잘 복원됨, 고주파의 Moire가 다소 없어짐
 - 하지만 고주파 image의 detail이 사라짐, 저주파의 Moire는 여전히 존재
 - Tone mapping도 3x3 convolution 을 사용함
 - Moire pattern의 제거에 MPRB가 기여



Method

- MBCNN+*

- Ablation Study: MPRB, GTMB, LTMB

- GTMB가 channel attention 과 비슷함
 - MPRB제거 시 2.88dB의 하락 GTMB제거 시 4.24dB의 하락
 - 효과가 가장 작은것은 LTMB

↳ MPRB에서 Moire를 지우면서 local tone mapping이 되기 때문

- GTMB가 channel attention 보다 1.39dB 높음

↳ Sigmoid activation, channel 감소는 global color adjustment의 기능을 약화시킴

MPRB	GTMB	LTMB	CA	PSNR	SSIM
✗	✓	✓	✗	41.38	0.9869
✓	✗	✓	✗	40.02	0.9890
✓	✓	✗	✗	43.35	0.9895
✓	✗	✓	✓	42.87	0.9893
✓	✓	✓	✗	44.26	0.9962

Method

- MBCNN+*
 - Multi Learnable bandpass filter

- Frequency Domain Transform을 비교
- Weight θ^{s_i} 를 1개 추가할 때 0.16dB, 2개 추가할 때 0.22dB의 상승

< LBF의 비교 >

	LBF			MLBFs	
p	8	8	8	{6, 8}	{4, 6, 8}
Structure	w/o. FDT	w/o. LP	FDT and LP	-	-
PSNR	42.91	43.09	44.04	44.20	44.26
SSIM	0.9932	0.9936	0.9948	0.9958	0.9962

Method

- MBCNN+*

- Dialation ASL

- Sobel : edge, gradient의 개념이 추가 됨. 1.24dB 의 상승
- ASL : 가로세로 방향에서 대각선 2방향을 추가함 0.83dB의 상승
- Perceptual : vgg16의 feature extraction 이 가능한 장점을 사용, ASL과 유사한 성능
- SSIM: Sobel loss와 유사

< Loss의 비교 >

	Loss	λ	PSNR (dB)	SSIM
Other	L1	-	42.19	0.9941
	L1 + Sobel	0.5	43.43	0.9956
	L1 + Laplace	0.5	43.02	0.9950
	L1 + SSIM	0.2	43.25	0.9958
	L1 + perceptual	1.0	44.39	0.9961
	L1 + Wavelet	0.6	40.66	0.9925
Proposed	L1 + ASL	0.25	44.26	0.9962
	L1 + D-ASL ^{1,2}	0.25	44.78	0.9964
	L1 + D-ASL ^{1,2,3}	0.25	45.08	0.9967
	L1 + D-ASL ^{1,2,3,4}	0.25	44.76	0.9964

Method

- MBCNN+*

- Dialation ASL

- Dialation 된 loss를 추가함으로서 더 넓은 frequency를 수용가능
- Dialation이 많이 되는 것은 낮은 주파수도 고려하게 됨으로서 성능이 하락

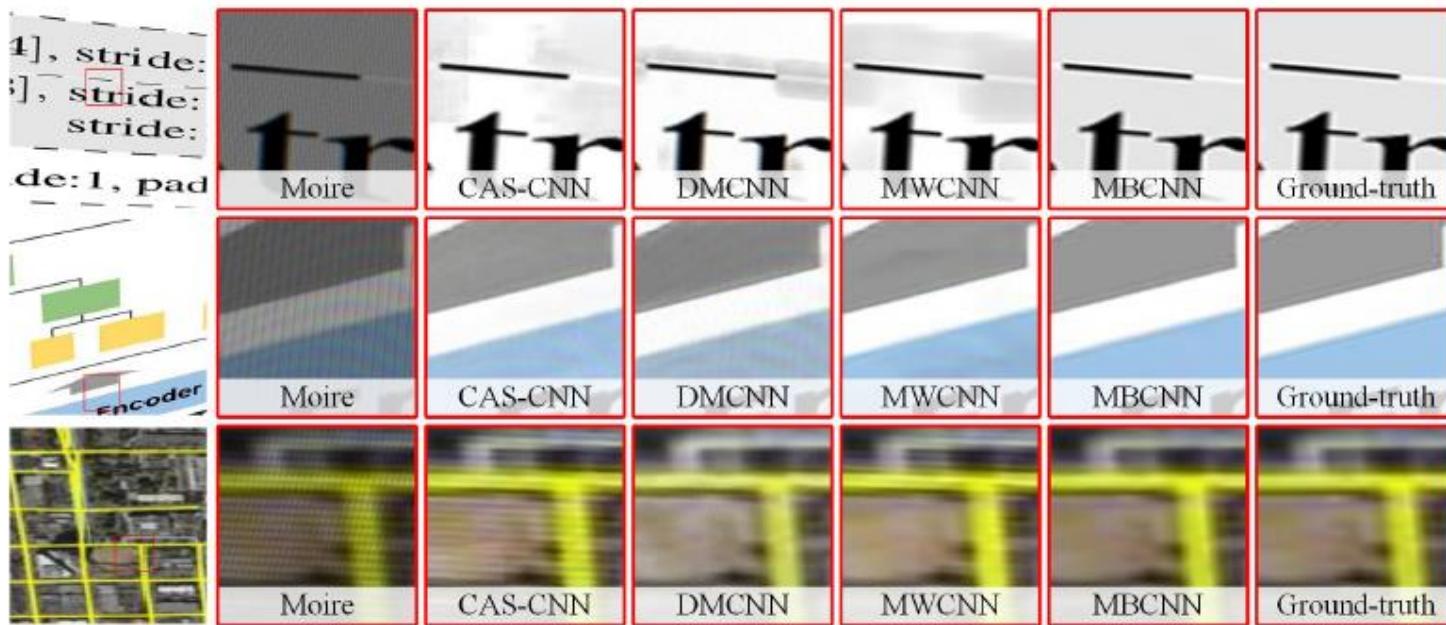
< Loss의 비교 >

	Loss	λ	PSNR (dB)	SSIM
Other	L1	-	42.19	0.9941
	L1 + Sobel	0.5	43.43	0.9956
	L1 + Laplace	0.5	43.02	0.9950
	L1 + SSIM	0.2	43.25	0.9958
	L1 + perceptual	1.0	44.39	0.9961
	L1 + Wavelet	0.6	40.66	0.9925
Proposed	L1 + ASL	0.25	44.26	0.9962
	L1 + D-ASL ^{1,2}	0.25	44.78	0.9964
	L1 + D-ASL ^{1,2,3}	0.25	45.08	0.9967
	L1 + D-ASL ^{1,2,3,4}	0.25	44.76	0.9964

Method

- MBCNN+*
 - Comparison with prior work

- Global tone mapping이 색상의 복원을 함
- 다른 model들은 불규칙, 비정형적인 artifact가 생김



Summary

- Conventional 한 Demoire는 CNN을 사용
- Frequency Domain Transform을 통해 Demoire를 하는 추세
- Frequency에 weight를 더해서 frequency domain 을 학습이 가능하게 함.
- MBCNN + FHDe²Net
 - Autoencoder와 learnable weight를 추가
 - MBCNN은 parameter가 많은 Network > 다른 Network와의 결합??