

# Single image denoising with generalization

## 2024년도 하계 세미나

---



*Sogang University*

*Vision & Display Systems Lab, Dept. of Electronic Engineering*



*Presented By*

*Yeongje Im*

# Outline

- Background
  - Image denoising
- Real-World Mobile Image Denoising Dataset with Efficient Baselines
  - CVPR 2024
- Transfer CLIP for Generalizable Image Denoising
  - CVPR 2024

# Background

- **Image denoising**

- **Image에서 noise가 생기는 원인**

- 조도가 낮은 환경의 경우, 카메라의 high ISO setting으로 빛에 더 민감하게 촬영을 해야함

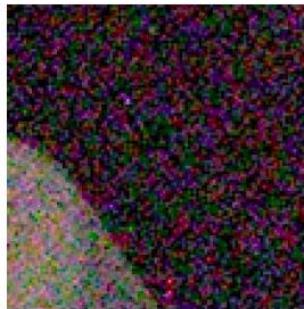
- ↳ 이러한 high ISO는 noise도 민감하게 반응하여 noise 신호가 증폭이 됨

- Low ISO와 long exposure을 이용해서 “noise free” image 제작 가능

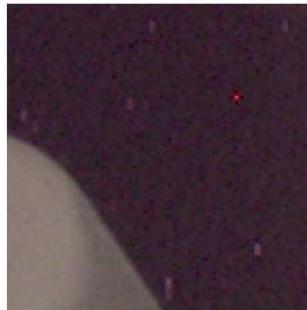
- ↳ Smartphone camera에서는 applicable X, pair로 밝기 맞추기도 힘들



(a) Low-light noisy image



(b) Zoom-in region from (a)



(c) Mean image with defective pixels



(d) Our ground truth with defective pixels corrected

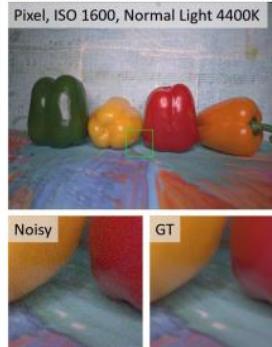
Clean GT 예시



Noisy



GT



Noisy



GT



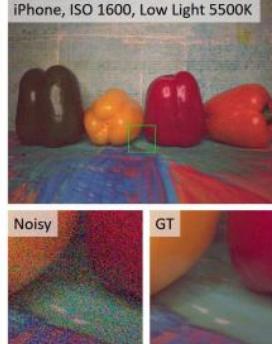
GT



Noisy



GT



Noisy



GT



Noisy



GT

Noisy clean pair image 예시

# Background

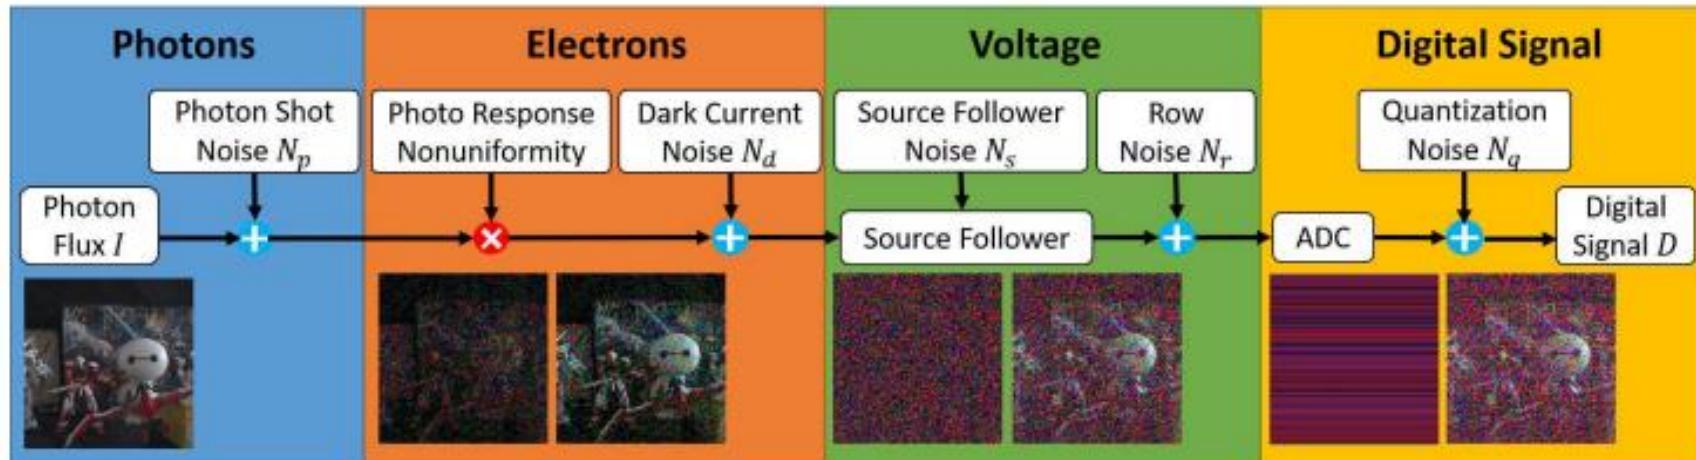
- **Image denoising**

- Image에서 noise가 생기는 원인(not ISO, physics-inspired)

- Gain을 높혀서 생기는 noise와 별도로 camera sensor 자체에서 생기는 noise도 존재
    - Shot noise의 경우, signal dependent noise로 들어오는 signal에 따라 noise가 발생
    - ADC(analog digital converter)에서 image를 quantization을 수행하면서 noise가 발생
    - 또한 저조도 조건에서 ISO가 높을 경우, banding noise(row-column noise)가 발생

※ 위성 사진에서 대표적으로 나타나며, 영상일 경우 시간 축 걸쳐서 나타나기도 함

- CMOS sensor 자체 결함으로도 noise가 발생
    - 또한 이후 ISP를 통과할 경우, camera ISP noise가 발생하기도 함

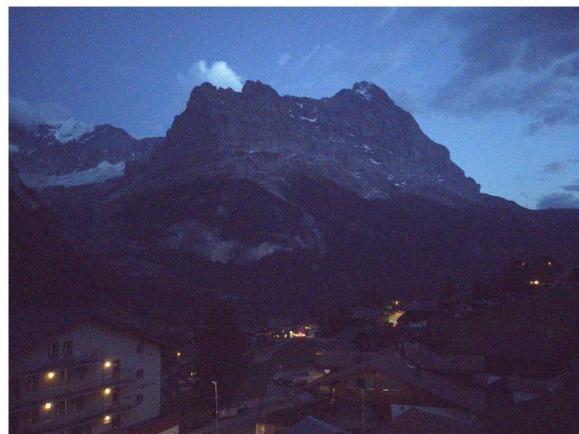


Real noise in camera sensor

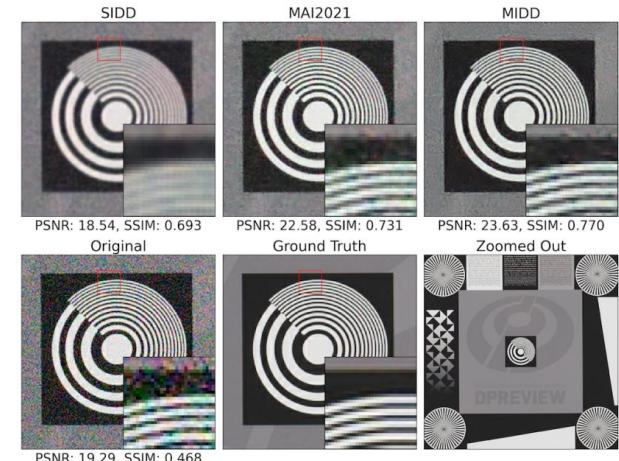
Flepp, Roman, et al. "Real-World Mobile Image Denoising Dataset with Efficient Baselines." CVPR, 2024.

# Introduction

- Mobile image denoising
  - DSLR photography에서는 longer exposure time과 lower ISO setting을 이용하여 image noise 줄임
    - Mobile photography에서는 camera sensor의 movement 등과 같은 이유로 적합 X
    - ;; Higher ISO level setting이 더 바람직함
  - 현존하는 mobile image dataset SIDD의 경우 10개의 실내 장면과 5개의 카메라 센서로만 촬영
    - DND의 경우 여러 시나리오의 장면을 담고 있지만 50개의 이미지만 있어 학습에 적합X
  - 본 논문의 저자들은 다양한 실제 시나리오에 적합한 대규모 mobile image dataset을 제안
    - 여기에 더해 DPreview test dataset도 같이 제공하여 dataset의 품질 분석이 가능
    - Android Neural Network API를 활용 AI 가속 가능한 모든 device에 원활하게 실행가능한 SplitterNet 배포



MIDD outdoor noisy clean pair image



SIDD, MIDD 결과 비교

# Dataset

- Dataset collection

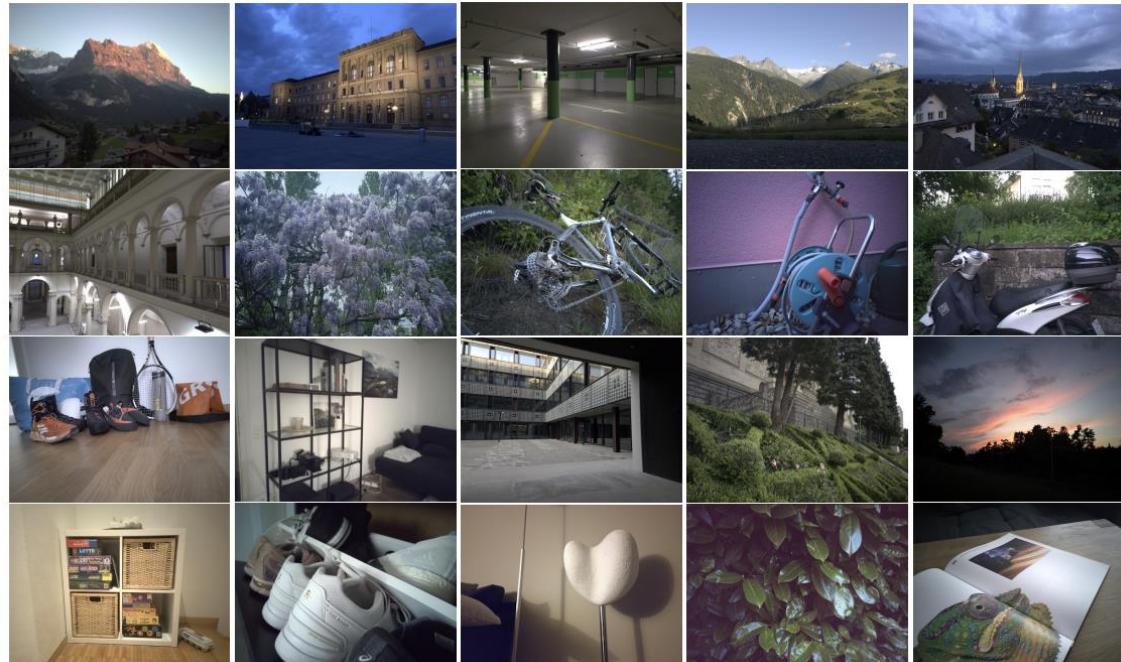
- 저자들의 목표는 다양한 mobile camera sensor를 사용하여 다양한 시나리오를 촬영

- 20개의 mobile camera sensor를 이용하여 2만 장의 noise image를 수집

- Camera2 API를 사용하여 ISP를 우회하여 RAW Bayer 이미지를 burst 모드로 촬영

- Dataset의 약 20%은 낮에 촬영, 60%은 less ideal condition, 20%은 야간 및 낮은 조명에서 촬영

- 총 40만 장(burst 당 20장 x 1000scene x 20sensor)으로 다양한 실내외 장면



MIDD dataset

# Dataset

- Sensor
  - 대규모 dataset의 noise 분포 다양성을 위해 다양한 제조업체 sensor를 사용
    - Sony, ISOCELL, OmniVision and Hynix의 mobile camera sensor 사용
  - RGB Image Retrieval
    - Capture한 RAW 이미지는 최소한의 ISP(LibRaw)를 사용하여 RGB format으로 변환  
↳ CMOS sensor의 Bayer pattern demosaicing 또한 RawPy로 처리

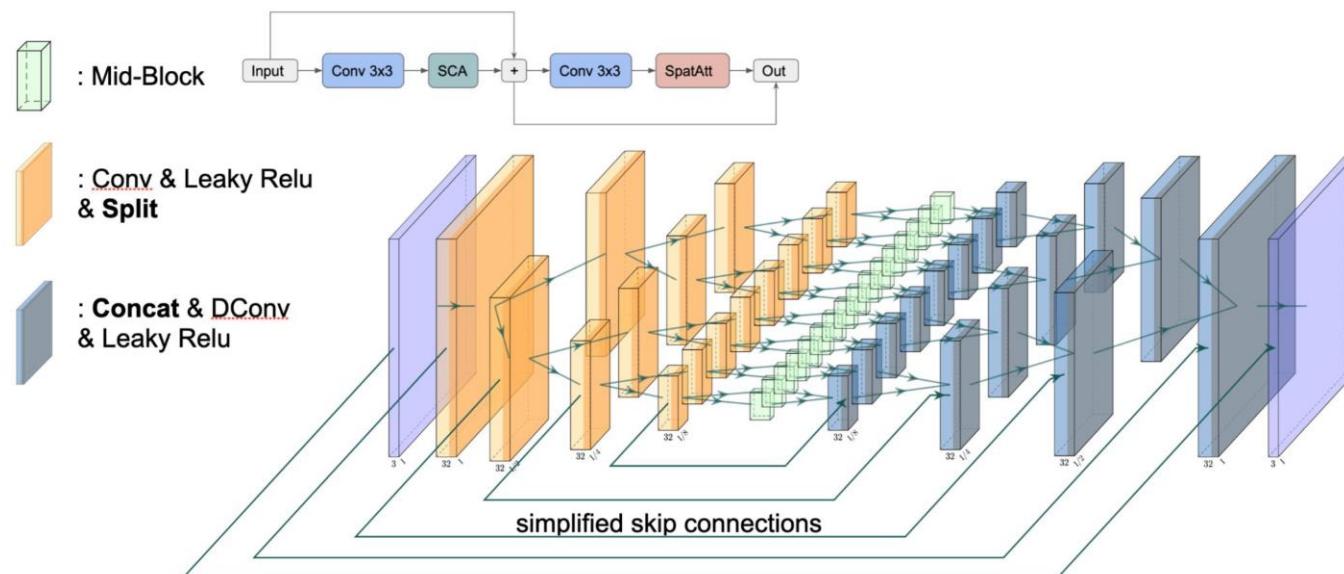
Sensor	Sensor Resolution	Pixel Size	Year	Sensor	Type	Phone
Sony IMX179	8 MP ( $3288 \times 2512$ )	$1.4 \mu\text{m}$	2017	RGB	Front	Google Pixel 2
Sony IMX258	13 MP ( $4224 \times 3136$ )	$1.12 \mu\text{m}$	2015	RGB / Monochrome	Main	Essential Phone
Sony IMX268	8 MP ( $3840 \times 2160$ )	$1.12 \mu\text{m}$	2016	RGB	Front	Essential Phone
Sony IMX351	16MP ( $4656 \times 3496$ )	$1.0 \mu\text{m}$	2018	RGB	Main	LG G7 ThinQ
Sony IMX362	12 MP ( $4000 \times 3000$ )	$1.4 \mu\text{m}$	2017	RGB	Main	Google Pixel 2
Sony IMX476	20 MP ( $5184 \times 3888$ )	$1.0 \mu\text{m}$	2019	RGB	Front	Nokia 9
Sony IMX586	48 MP ( $8000 \times 6000$ )	$0.8 \mu\text{m}$	2018	RGB / Quad Bayer	Main	Honor View 20
Sony IMX686	64 MP ( $9248 \times 6944$ )	$0.8 \mu\text{m}$	2019	RGB / Quad Bayer	Main	Realme X7 Pro
Sony IMX766	50MP ( $8192 \times 6144$ )	$1.0 \mu\text{m}$	2020	RGB / Quad Bayer	Main	Snapdragon Phone
ISOCELL 3J1	10 MP ( $3648 \times 2736$ )	$1.22 \mu\text{m}$	2019	RGB	Front	Google Pixel 6
ISOCELL 2L4	12 MP ( $4032 \times 3024$ )	$1.4 \mu\text{m}$	2019	RGB / Bayer	Main	Samsung Galaxy S10
ISOCELL 3P9	16 MP ( $4608 \times 3456$ )	$1.0 \mu\text{m}$	2018	RGB / Tetracell	Front	Oppo A92s
ISOCELL 3T2	20 MP ( $5184 \times 3880$ )	$0.80 \mu\text{m}$	2020	RGB / Dual Tetrapixel	Front	Redmi K30 Ultra
ISOCELL 3M5	50 MP ( $8160 \times 6144$ )	$0.8 \mu\text{m}$	2021	RGB / Bayer	Main	Xiaomi Mi 9
ISOCELL GN1	50 MP ( $8160 \times 6144$ )	$1.2 \mu\text{m}$	2020	RGB / Dual Tetrapixel	Main	Google Pixel 6
ISOCELL HM3	108 MP ( $12000 \times 9000$ )	$1.0 \mu\text{m}$	2021	Nonapixel RGB Bayer	Main	Samsung Galaxy S22 Ultra
OmniVision OV32A	32MP ( $6560 \times 5480$ )	$0.8 \mu\text{m}$	2019	RGB	Front	Realme X7 Pro
OmniVision OV48B	48 MP ( $8000 \times 6000$ )	$0.8 \mu\text{m}$	2019	RGB / Quad Bayer	Main	Oppo A92s
OmniVision OV64B	64MP ( $9248 \times 6944$ )	$0.7 \mu\text{m}$	2020	RGB	Front	Snapdragon Phone
Hynix SL846	8 MP ( $3264 \times 2448$ )	$1.125 \mu\text{m}$	-	RGB	Front	LG G7 ThinQ

MIDD dataset 수집에 사용된 sensor

# Method

- SplitterNet

- SplitterNet architecture는 smartphone NPU와 GPU의 mobile AI accelerator를 고려하여 개발
  - Model complexity를 줄이기 위해 tensor를 더 작게 분할(channel axis)한 뒤에 convolution 연산 적용  
↳ Split operation의 경우 MAI2021 challenge에서 보여준 좋은 성능을 참고
  - Middle block에서 spatial, channel attention을 사용하여 중요 feature 추출  
↳ Encoding, decoding level 만큼 parallel middle block 수행
  - Decoding block은 transposed convolution과 skip connection layer 수행  
↳ Transposed convolution layer에서 channel number는 줄고 spatial dimension은 확장



SplitterNet 구조

# Result

- Quantitative Evaluation

- MIDD dataset으로 NAFNet, U-Net, ResNet18, NOAHTCV, Megvii 모델들과 성능 비교
  - NOAHTCV, Megvii network는 MAI2021 efficient image denoising challenge에서 winning solution
  - NAFNet의 경우 image denoising과 reconstruction tasks에서 최근 baseline
- Runtime은 Exynos 2200 Mali GPU에서 720×480의 해상도 이미지 처리 시간
  - SplitterNet model이 ResNet, U-Net model보다 3.5–6 times 빠른 결과
  - NAFNet model의 경우 mobile inference로 하기에는 너무 무거워서 다른 platform에서 수행
- SplitterNet architecture는 NOAHTCV와 비슷한 latency를 가졌지만 더 높은 PSNR, SSIM
  - Megvii와 비교했을 때는 PSNR 수치는 더 낮지만 runtime이 2times 빠른 결과

Model	PSNR	SSIM	Runtime, ms
Identity Mapping	30.88	0.673	-
NAFNet [12]	37.27	0.869	-
ResNet 18 [15]	37.48	0.881	186.0
U-Net [24]	37.87	0.883	95.0
Megvii [16]	<b>38.05</b>	<b>0.884</b>	56.8
NOAHTCV [16]	37.81	0.883	30.4
SplitterNet (ours)	37.92	<b>0.884</b>	<b>27.7</b>

Quantitative evaluation 결과

Model	PSNR	SSIM	Runtime, ms
Identity Mapping	30.86	0.672	-
Model (1)	37.50	0.877	<b>17.5</b>
Model (2)	37.85	0.883	-
Model (3)	<b>38.00</b>	<b>0.883</b>	56.1
SplitterNet	37.93	0.882	27.7

Ablation study

# Result

- Qualitative Evaluation

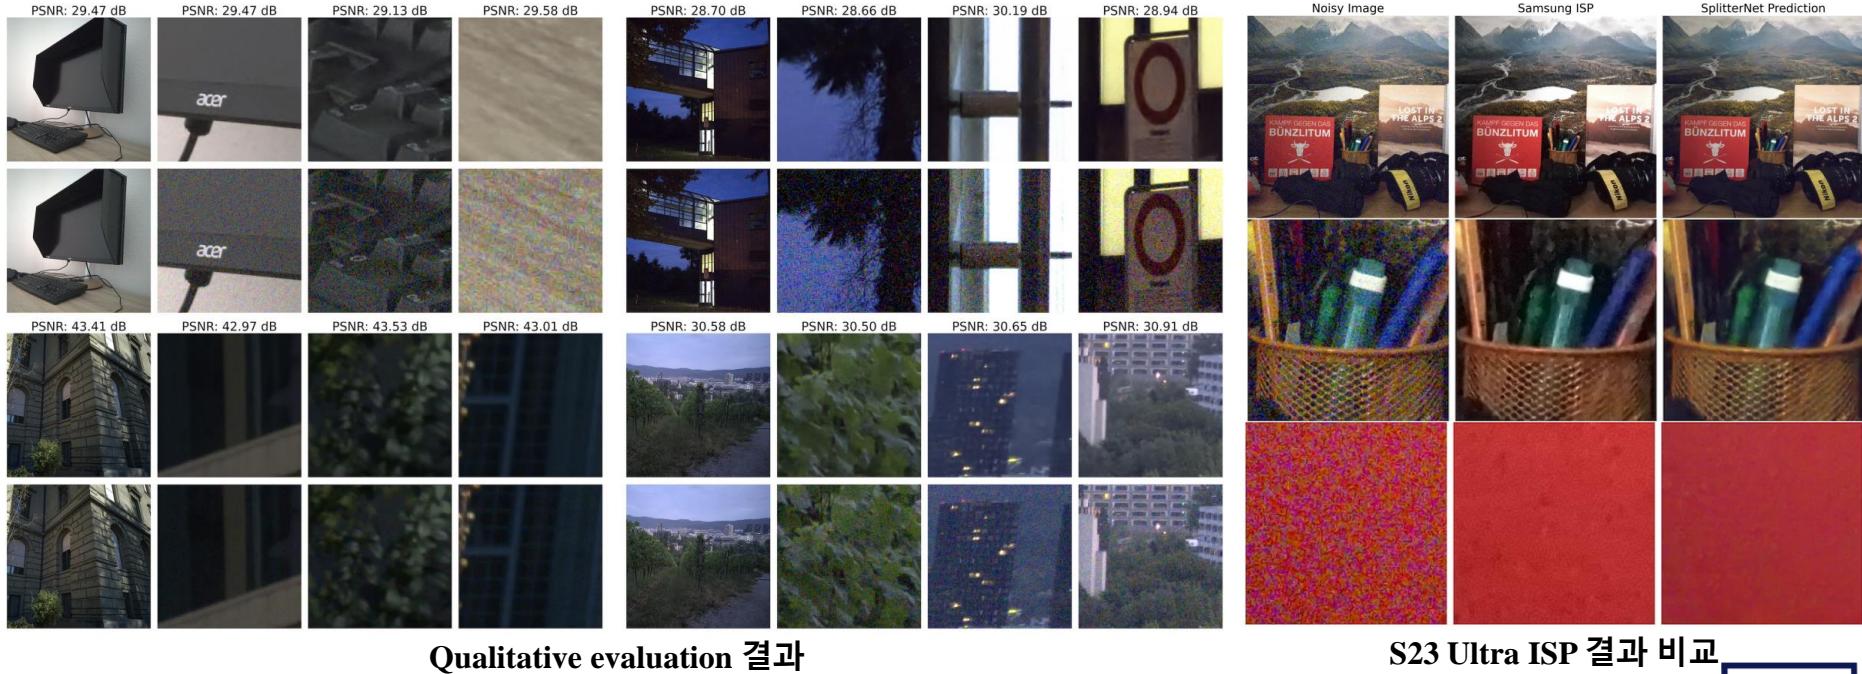
- Over-smoothing 없이 sharpness를 유지하는 결과를 보여줌

- 모든 condition(다양한 조명 조건)에서 model이 잘 수행하는 것을 확인

- 또한 noise의 정도에 상관없이 균일하게 모두 denoising이 잘 되는 결과를 보여줌

- S23 Ultra ISP와 SplitterNet 결과 비교

- Qualitative 결과로 S23 Ultra ISP로 처리한 결과와 비교



Qualitative evaluation 결과

S23 Ultra ISP 결과 비교

# Result

- Runtime Evaluation

- Real-world condition에서 큰 해상도 image에 대한 SplitterNet model runtime 결과

- High-end mobile SoC에서 얻은 runtime 결과
    - 모든 mobile SoC에서 8MP( $4000 \times 2000$ ) photo를 처리하는데 1초 미만
    - Snapdragon8 Gen 3 / 2, Dimensity 9000 NPU에서 모델을 배포할 때 HD-resolution image에서 real-time  
Over 30 FPS, video data denoising 가능

Mobile Chipset	Accelerator	720×480	HD	Full HD	4MP	8MP
		ms	ms	ms	ms	ms
Qualcomm Snapdragon 8 Gen 3	GPU (Adreno 750)	19	43	91	159	336
Qualcomm Snapdragon 8 Gen 2	GPU (Adreno 740)	21	49	110	195	426
Qualcomm Snapdragon 8 Gen 1	GPU (Adreno 730)	45	100	219	369	869
Qualcomm Snapdragon 888	GPU (Adreno 660)	37	97	220	395	910
MediaTek Dimensity 9300	GPU (Immortalis-G720 MC12)	24	50	103	178	357
MediaTek Dimensity 9200	GPU (Immortalis-G715 MC11)	27	72	130	216	409
MediaTek Dimensity 9000	GPU (Mali-G710 MC10)	32	71	160	271	578
Samsung Exynos 2200	GPU (Xclipse 920)	28	66	144	261	542
Samsung Exynos 2100	GPU (Mali-G78 MP14)	36	86	171	311	642
Google Tensor G2	GPU (Mali-G710 MP7)	75	133	240	374	751
Google Tensor G1	GPU (Mali-G78 MP20)	50	94	172	306	652
Qualcomm Snapdragon 8 Gen 3	NPU (Hexagon HTP Gen 3)	<b>7.3</b>	<b>20</b>	<b>48</b>	110	<b>257</b>
Qualcomm Snapdragon 8 Gen 2	NPU (Hexagon HTP Gen 2)	9	24	60	140	310
Qualcomm Snapdragon 8 Gen 1	NPU (Hexagon HTP Gen 1)	20	52	121	249	368
MediaTek Dimensity 9300	NPU (APU 790)	7.7	22	51	<b>99</b>	OOM
MediaTek Dimensity 9200	NPU (APU 690)	17	44	100	250	518
MediaTek Dimensity 9000	NPU (APU 590)	22	59	132	191	396

각 mobile chipset에서 runtime 결과

# Result

- Cross-Dataset Evaluation

- MIDD dataset은 real world image에서 noise를 제거할 때 학습된 model의 high robustness이 목표
  - MIDD dataset에 모델을 훈련한 뒤, 다른 dataset에 test 해 본 결과 기존 SIDD 결과보다 높은 수치
  - Target dataset에 대한 추가적인 fine-tuning을 진행한 결과 MIDD가 가장 좋은 성능을 보여줌
  - Model generalization을 평가하기 위해 19 camera sensor data로 학습을 하고 남은 하나로 test  
↳ 오른쪽 열이 identity score, 중간이 해당 센서 데이터 결과로 일반화가 잘 된 것을 보여줌

Trained on	Tested on			
	SIDD	MAI2021	MIDD	DPreview
SIDD [9]	<b>36.77</b>	36.00	34.03	21.13
MAI2021 [16]	34.85	37.07	34.69	20.55
MIDD	35.12	<b>37.23</b>	<b>37.92</b>	<b>21.75</b>
Identity	23.66	31.94	30.88	16.00

Cross dataset evaluation

Trained on	Fine-tuned and Tested on		
	SIDD	MAI2021	MIDD
SIDD	36.77	37.25	37.90
MAI2021	37.98	37.07	37.35
MIDD	<b>38.79</b>	<b>37.62</b>	<b>37.92</b>
Identity	23.66	31.94	30.88

Cross dataset evaluation(finetune)

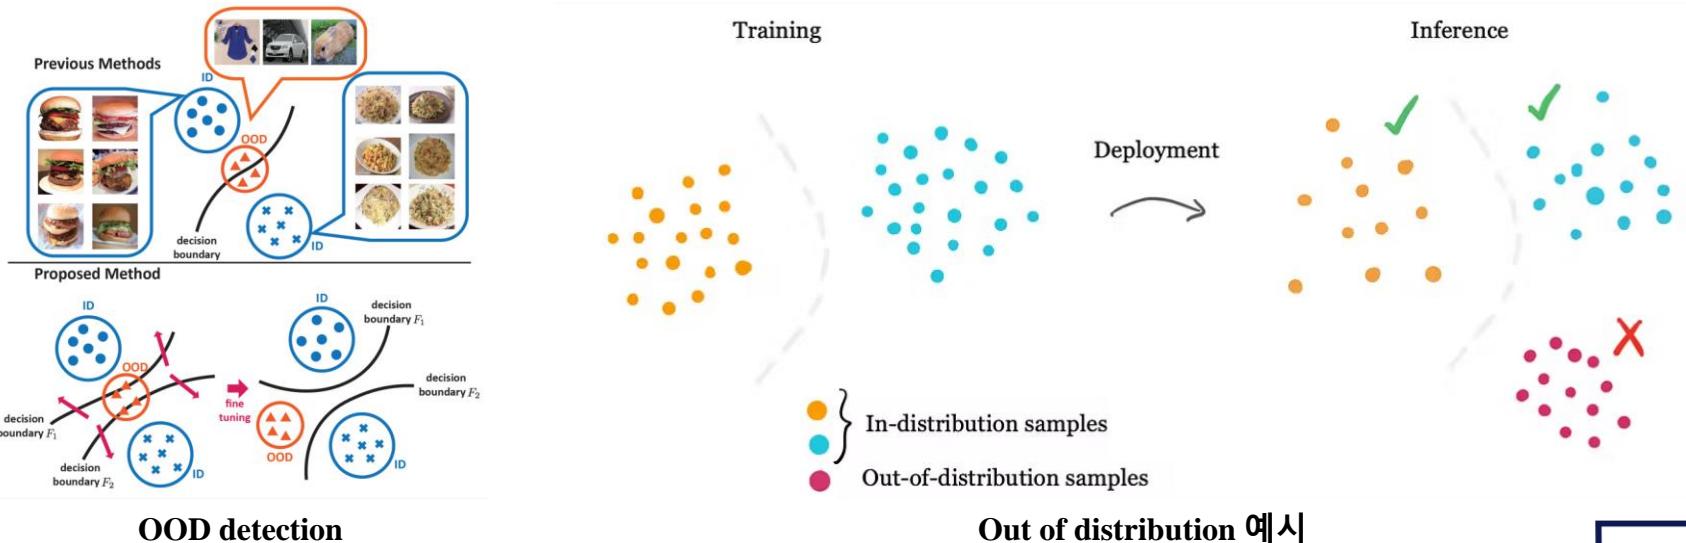
Sensor	PSNR/SSIM	Id PSNR/SSIM
OV48B	38.73 / 0.912	32.59 / 0.722
OV64B	37.97 / 0.880	30.64 / 0.660
OV32A	39.32 / 0.900	32.57 / 0.730
IMX179	35.26 / 0.792	26.23 / 0.522
IMX258	40.12 / 0.947	33.57 / 0.772
IMX268	40.22 / 0.913	31.66 / 0.674
IMX351	34.92 / 0.863	28.07 / 0.568
IMX362	33.67 / 0.805	25.58 / 0.472
IMX476	39.02 / 0.900	37.15 / 0.867
IMX586	36.32 / 0.900	31.78 / 0.740
IMX686	36.31 / 0.838	28.00 / 0.575
IMX766	39.36 / 0.922	31.93 / 0.687
ISOCELL 3M5	31.63 / 0.792	25.37 / 0.481
ISOCELL GN1	36.41 / 0.817	29.62 / 0.601
ISOCELL 3J1	41.83 / 0.912	36.56 / 0.795
ISOCELL 2L4	37.37 / 0.899	30.41 / 0.683
ISOCELL 3P9	39.66 / 0.949	34.89 / 0.830
S5KHM3	37.98 / 0.912	32.11 / 0.761
S5K3T2	37.52 / 0.854	31.11 / 0.693
Hynix SL846	37.95 / 0.844	29.26 / 0.592

한 개의 sensor dataset을 제외하고 inference 결과

Cheng, Jun, Dong Liang, and Shan Tan. "Transfer CLIP for Generalizable Image Denoising." CVPR 2024.

# Introduction

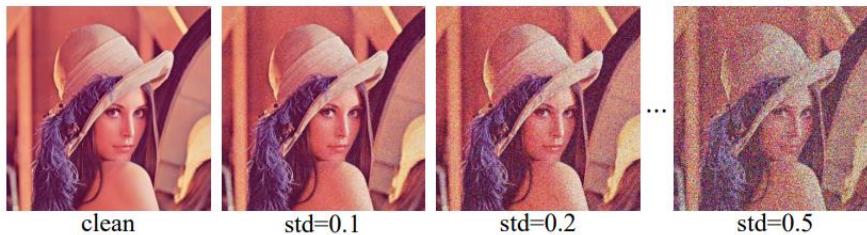
- OOD(out of distribution)
  - 현존하는 supervised denoiser는 training dataset에 overfit, OOD noise 일반화에서 성능 떨어짐
    - Unsupervised, self-supervised denoising method는 일반화 문제에서 자유로운 편  
하지만 성능 자체가 supervised 보다 좋지 못하고 추가 noisy dataset 수집이 현실적으로 불가능
  - 본 논문의 저자들은 CLIP ResNet image encoder가 특정 scale feature map에서 noise 저항성 발견
    - CLIP ResNet encoder의 distortion-invariant와 content related property를 활용하여 일반화된 denoiser 구축
    - Robustness를 개선하기 위해 progressive feature augmentation strategy 제안
    - Denoising 분야에서 처음으로 CLIP을 사용하여 syntactic noise로 다양한 real noise 제거가 가능함을 입증



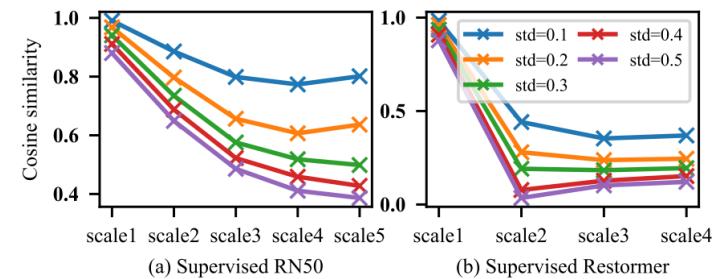
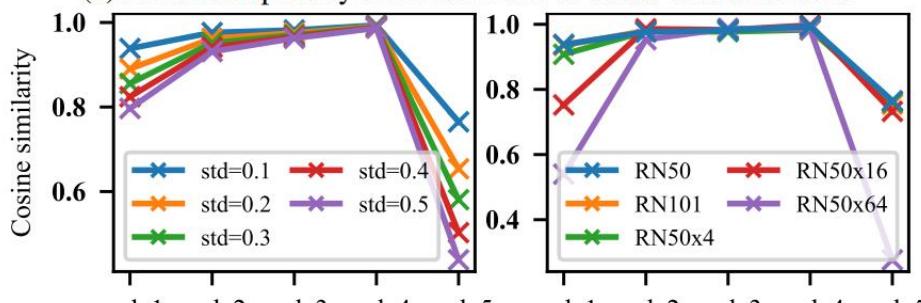
# Method

- Analyzing Features of CLIP Image Encoder
  - Distortion-invariant property

- CLIP ResNet image encoder는  $F^i \in R^{\frac{H}{2^i} \times \frac{W}{2^i} \times 2^i C}$ ,  $i \in \{2, \dots, 5\}$  5개의 multi-scale feature를 산출
- OI feature들의 robustness를 평가하기 위해 clean image  $I_c$ 와 일치하는 Gaussian noisy image  $I_n$  생성
- Frozen ResNet을 통과하여  $F_c^i$ 와  $F_n^i$  사이에 cosine similarity를 계산
- RN50은 다양한 corruption level에서 처음 4개의 feature가 similarity가 높은 것을 확인
- Image classification ResNet50(no CLIP), Restormer와 비교한 결과 similarity가 낮은 것을 확인

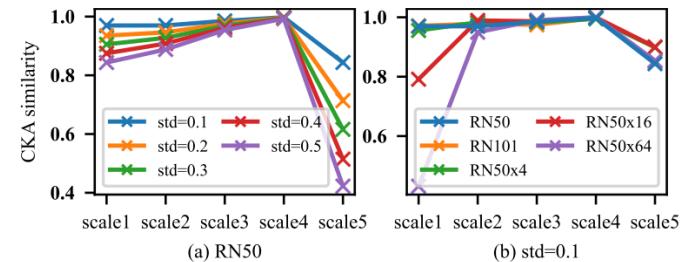


(a) Lena corrupted by different levels of i.i.d. Gaussian noise



(a) Supervised RN50      (b) Supervised Restormer

ResNet(no CLIP), Restormer similarity 비교



CKA similarity 결과

# Method

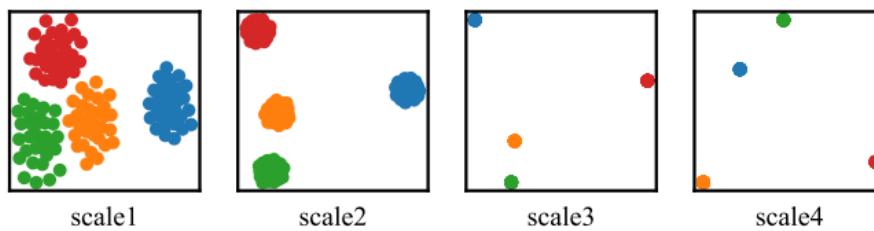
- Analyzing Features of CLIP Image Encoder

- Content-related property

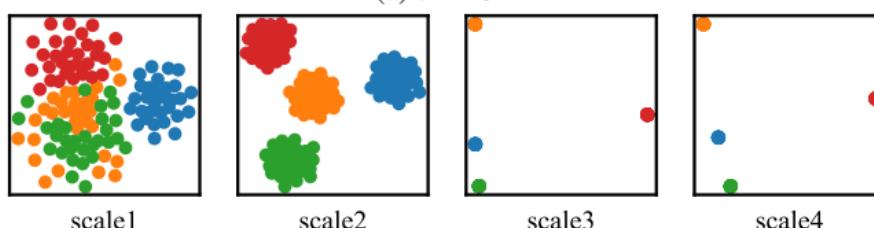
- 다중 noisy image  $I_m^n$  ( $m \in \{1, \dots, M\}$ )에서 RN50을 통과한 다중 스케일 feature를 t-SNE 방법으로 임베딩
  - $I_m^n$ 에서 얻어진  $F_i^n$ 이 서로 다른 스케일  $i$ , 다른 noise level에서 명확히 분리되는 것을 발견

- Building a Generalizable Denoiser

- Encoder  $F_i^n$  ( $i \in \{1, 2, 3\}$ )이 decoder up-sampling feature 와 복원 과정에서 concatenated
  - Learnable decoder는 encode와 동일하게 convolution 기반(Conv-ReLU-Conv-ReLU sequence로 구성)
  - $I_n$ 은 image detail을 가지고 있어 추가적으로 decoder에서 concatenated

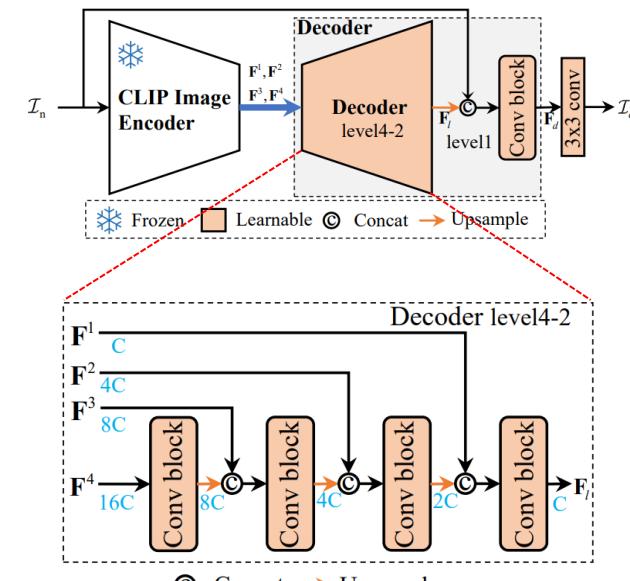


(a)  $\sigma = 0.1$



(b)  $\sigma = 0.2$

t-SNE 임베딩 결과



CLIPdenoising model 구조

# Experiments

- Experimental Settings

- Synthetic noise

- AWGN(additive white gaussian noise)  $\sigma = 15$ 로 설정하여 train과정에서 사용(in-distribution noise)

- ;; CBSD432 dataset을 train할 때 사용(online fashion)

- 5개 종류의 synthetic OOD noise로 inference 진행

- ;; Kodak24, McMaster, CBSD68, Urban100 dataset을 test set으로 사용

- ;; AWGN(additive white gaussian noise)  $\sigma \in \{25, 50\}$

- ;; Spatial Gaussian noise  $\sigma \in \{45, 50, 55\}$

- ;; Poisson noise  $\alpha \in \{2.5, 3, 3.5\}$

- ;; Speckle noise  $\sigma^2 \in \{0.02, 0.03, 0.04\}$

- ;; Salt&Pepper noise  $d \in \{0.012, 0.016, 0.02\}$

- Real-world sRGB noise

- DIV2K dataset을 Poisson-Gaussian noise fixed level  $\sigma_s = 0.04, \sigma_c = 0.03$ 로 train 진행

- ;; Training, testing 사이에 distribution gap으로 raw domain에서 noise generate

- SIDD validation dataset, PolyU, CC dataset을 test set으로 사용

# Experiments

- Experimental Settings

- Synthetic Noise Removal

- 일반화 가능한 denoising 방식인 MaskDenoising, DIL, HAT 방식과 비교 실험 진행

- ;; MaskDenoising은 officially trained model 사용, DIL HAT는  $\sigma \in \{5, 10, 15, 20\}$ ,  $\sigma \in \{0, 25\}$ 로 각각 학습

- ;; DnCNN, Restormer(multiple noise level 고려 X 모델)은  $\sigma = 15$ 로 훈련 진행

- CLIPDenoising은 in-distribution performance가 좋으면서 OOD noise에도 robustness한 결과

- Restormer가 in-distribution performance가 좋기는 하지만 이는 train dataset에 overfitting 결과

Noise Types	Datasets	DnCNN [62]	Restormer [60]	MaskDenoising [6]	HAT [58]	DIL [32]	Ours
$\sigma = 50$	CBSD68	19.84/0.363	19.92/0.365	20.68/0.432	20.95/0.441	<u>26.43/0.717</u>	<b>26.69/0.731</b>
	McMaster	20.18/0.312	20.47/0.312	20.63/0.379	20.79/0.364	<u>26.61/0.669</u>	<b>27.43/0.727</b>
	Kodak24	19.78/0.301	20.12/0.321	20.72/0.368	21.04/0.390	<b>27.46/0.736</b>	<u>27.39/0.723</u>
$\sigma = 55$	Urban100	19.62/0.420	19.36/0.437	20.51/0.485	20.80/0.492	<u>25.89/0.768</u>	<b>26.27/0.769</b>
	CBSD68	25.91/0.699	23.51/0.595	<u>26.72/0.762</u>	26.39/0.713	24.61/0.630	<b>27.60/0.797</b>
	McMaster	26.18/0.649	24.01/0.539	<u>26.89/0.709</u>	26.62/0.665	24.82/0.574	<b>28.31/0.775</b>
$\alpha = 3.5$	Kodak24	25.98/0.653	22.99/0.533	<u>27.28/0.745</u>	26.40/0.671	24.56/0.572	<b>28.29/0.786</b>
	Urban100	25.55/0.727	24.13/0.660	<u>26.10/0.788</u>	26.48/0.742	24.80/0.673	<b>27.68/0.822</b>
	CBSD68	24.37/0.627	22.20/0.559	24.24/0.638	26.61/0.733	<u>27.64/0.819</u>	<b>27.67/0.818</b>
$d = 0.02$	McMaster	25.50/0.651	21.93/0.579	25.17/0.590	27.54/0.723	<b>28.91/0.825</b>	<u>28.81/0.820</u>
	Kodak24	24.49/0.560	22.55/0.517	24.30/0.572	27.10/0.695	<u>28.60/0.821</u>	<b>28.66/0.813</b>
	Urban100	23.57/0.649	21.08/0.584	23.90/0.669	25.95/0.746	<b>27.12/0.854</b>	<u>27.15/0.838</u>
$d = 0.02$	CBSD68	26.53/0.746	23.59/0.679	<u>29.74/0.843</u>	27.55/0.782	29.45/0.822	<b>29.81/0.844</b>
	McMaster	25.72/0.691	23.05/0.640	<u>29.28/0.773</u>	26.62/0.727	<u>29.28/0.773</u>	<b>29.79/0.807</b>
	Kodak24	27.10/0.723	23.81/0.639	<u>30.56/0.842</u>	28.19/0.766	29.99/0.810	<b>30.61/0.837</b>
$d = 0.02$	Urban100	25.61/0.777	23.51/0.734	28.43/0.861	26.88/0.792	<u>29.21/0.841</u>	<b>29.40/0.869</b>

Synthetic noise quantitative result 비교

# Experiments

- Experimental Settings

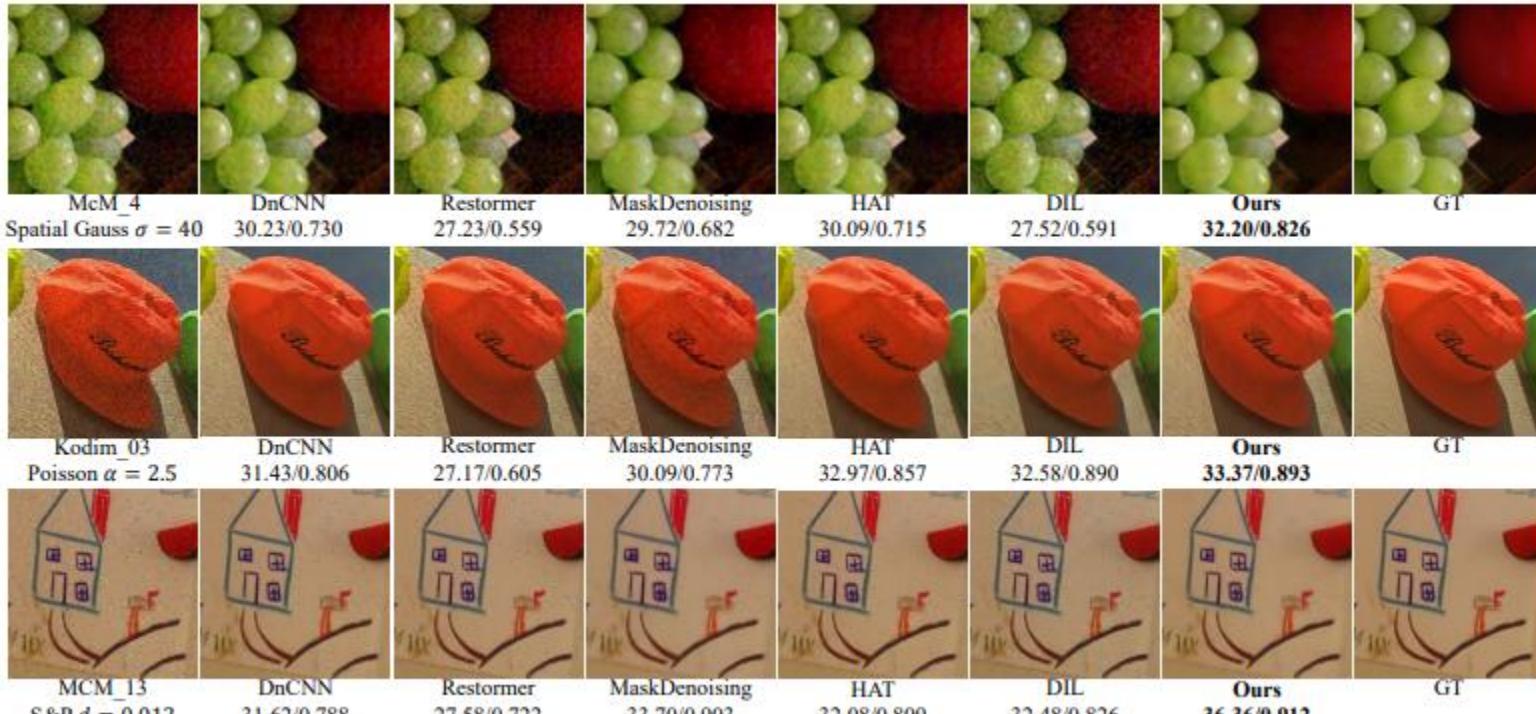
- Synthetic Noise Removal

- DIL과 CLIPDenoising이 유일하게  $\sigma = 50$  gaussian noise 제거에서 robustness한 결과

- ▷ CLIPDenoising이 DIL을 평균적으로 능가하는 결과

- CLIPDenoising은 모든 type에 OOD noise에서 competitive performance

- ▷ CLIP ResNet encoder의 distortion invariant property



Synthetic noise qualitative result 비교

# Experiments

- Experimental Settings

- Real-world sRGB Noise Removal

- MaskDenoising, DIL 모두 CLIPDenoising과 동일한 synthetic sRGB dataset으로 훈련
    - Unsupervised denoising method인 CVF-SID, LUD-VAE와 같이 비교

;; 이 방식들은 training에서 real-world noisy image가 필요함

- DIL은 CLIPDenoising과 성능 비슷
    - DIL은 training에서 4가지 distortion 필요
    - PolyU, CC 결과는 unsupervised 방식 능가

;; Unsupervised 방식보다 실용적

Methods	SIDD Val	PolyU	CC
MaskDenoising [6]	33.14/0.913	24.78/0.812	25.63/0.881
HAT [58]	28.58/0.570	37.25/0.948	35.27/0.901
DIL [32]	<u>34.76/0.848</u>	<u>37.65/0.959</u>	<u>36.10/0.948</u>
Ours	<b>34.79/0.866</b>	<u>37.54/0.960</u>	<b>36.30/0.941</b>
CVF-SID [44]	34.81/0.944	35.86/0.937	33.29/0.913
LUD-VAE [68]	34.91/0.892	36.99/0.955	35.48/0.941

Real noise quantitative result 비교



Real noise qualitative result 비교  
21

# References

- Abdelhamed, Abdelrahman, Stephen Lin, and Michael S. Brown. "A high-quality denoising dataset for smartphone cameras." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
- Flepp, Roman, et al. "Real-World Mobile Image Denoising Dataset with Efficient Baselines." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2024.
- Cheng, Jun, Dong Liang, and Shan Tan. "Transfer CLIP for Generalizable Image Denoising." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2024.
- Yu, Qing, and Kiyoharu Aizawa. "Unsupervised out-of-distribution detection by maximum classifier discrepancy." *Proceedings of the IEEE/CVF international conference on computer vision*. 2019.
- Zamir, Syed Waqas, et al. "Restormer: Efficient transformer for high-resolution image restoration." *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2022.
- Neshatavar, Reyhaneh, et al. "Cvf-sid: Cyclic multi-variate function for self-supervised image denoising by disentangling noise from image." *Proceedings of the ieee/cvf Conference on Computer Vision and Pattern Recognition*. 2022.
- Wei, Kaixuan, et al. "A physics-based noise formation model for extreme low-light raw denoising." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020.
- Monakhova, Kristina, et al. "Dancing under the stars: video denoising in starlight." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022.

# 감사합니다.