

# Extreme Low-Light Noise Modeling with Specific Sensor

## 2025년도 하계 세미나

---



***Sogang University***

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



***Presented By***

*Yeongje Im*

# Outline

- Background
  - Low-light noise
  - RAW denoising
  - Noise modeling
- Physics-Guided ISO-Dependent Sensor Noise Modeling for Extreme Low-Light Photography
  - CVPR 2023
- Noise Modeling in One Hour: Minimizing Preparation Efforts for Self-supervised Low-Light RAW Image Denoising
  - CVPR 2025

# Background

Extreme low-light condition  $D = I + \underbrace{N_{shot} + N_{DC}}_{\text{Signal dependent noise}} + \underbrace{N_{read} + N_{row} + N_q}_{\text{Signal independent noise}}$

Signal dependent noise    Signal independent noise

## • Low-light noise

• Image에서 noise가 생기는 원인(signal dependent noise)

Signal dependent noise

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

※ 이러한 high ISO는 noise도 민감하게 반응하여 noise 신호가 증폭이 됨(대표적으로 shot noise)

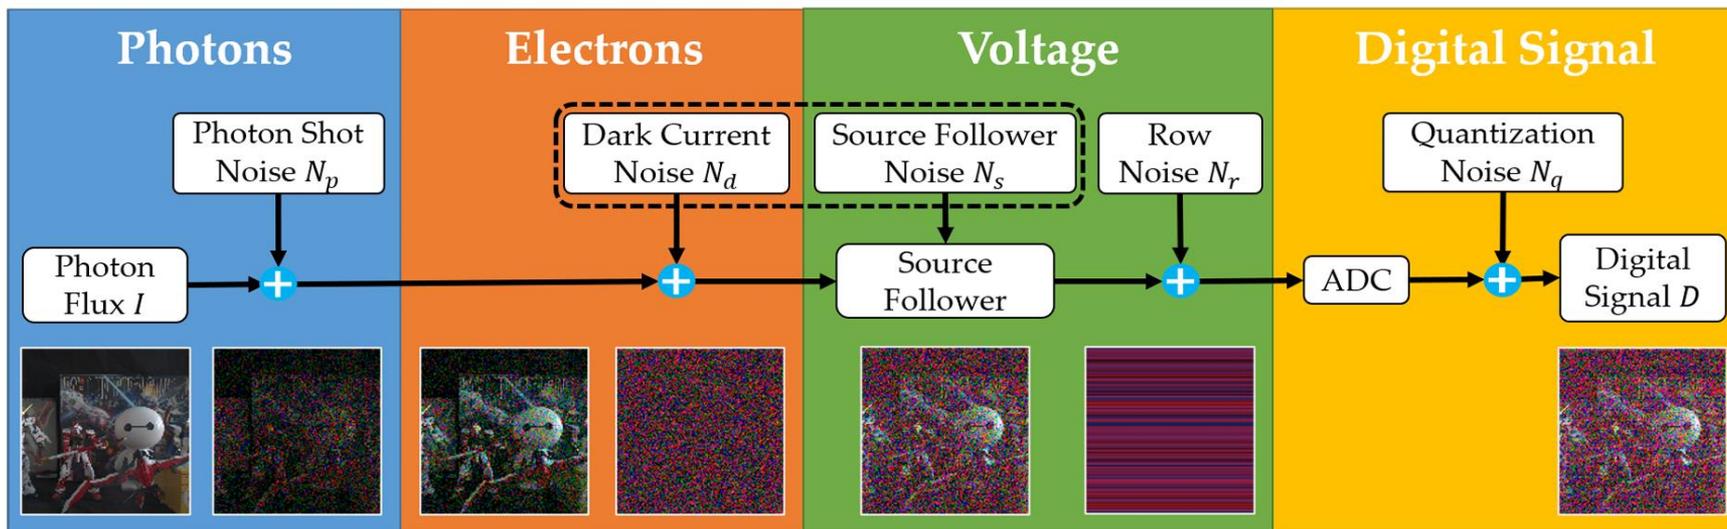
※ Exposure time을 늘려서 해결 가능하나 모션이 있으면 모션 blur 발생

- CMOS sensor의 thermal effect로 인해 noise가 발생

Camera analog gain

※ 대표적으로 dark current noise( $N_{DC}$ )  $N_{DC} = k \cdot N_{FP} + N_{BLE} + N_{DCSN}$

✓  $N_{FP}$ 의 경우 fixed pattern noise로 sensor 자체의 결함 noise에 해당



Real noise in camera sensor

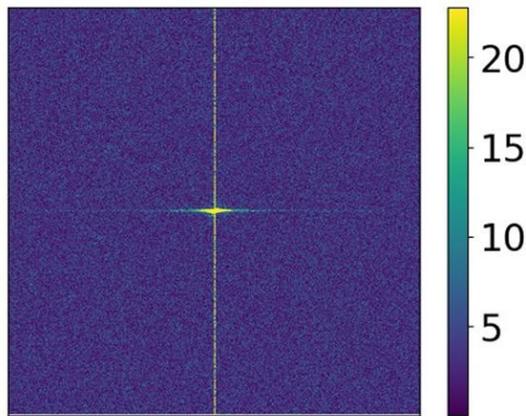
# Background

$$\text{Extreme low-light condition } D = I + \underbrace{N_{shot}}_{\text{Signal dependent noise}} + \underbrace{N_{DC} + N_{read} + N_{row} + N_q}_{\text{Signal independent noise}}$$

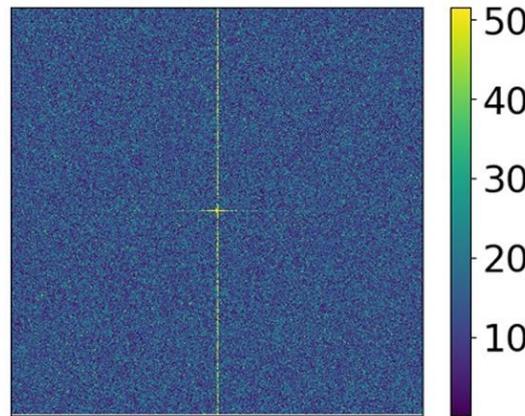
## • Low-light noise

### • Image에서 noise가 생기는 원인(signal independent noise)

- Sensor의 들어오는 photon으로 발생하는 shot noise와 별도로 signal independent noise도 존재
- ADC(analog digital converter)에서 image를 quantization을 수행하면서 noise가 발생
- 또한 저조도 조건에서 ISO가 높을 경우, banding noise(row noise)가 발생
  - ※ CMOS sensor가 row by row로 동작, 여기에 민감하게 반응한 결과
  - ※ 위성 사진에서 대표적으로 나타나며, 영상일 경우 시간 축 걸쳐서 나타나기도 함
- 일부 논문들(ELD 등)에서는 앞서 설명한 dark current noise를 signal independent noise 취급하기도 함
- 또한 이후 ISP를 통과할 경우, camera ISP noise가 발생하기도 함



Fourier spectrum of the bias frame

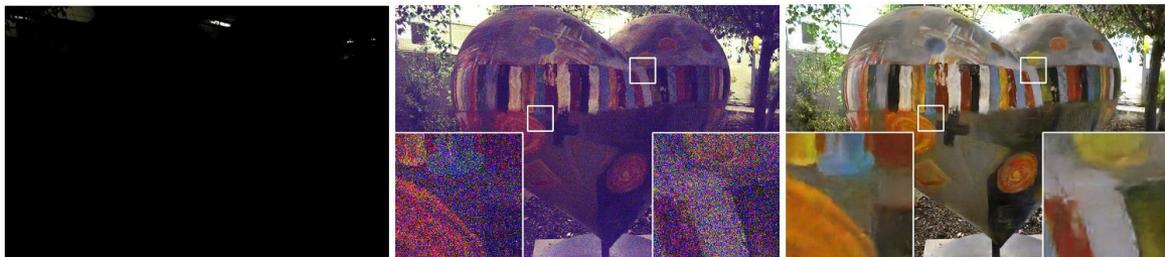


bias frame (SonyA7S2)

# Background

- RAW denoising

- RAW noise reduction의 필요성



- **RAW denoising:** RAW domain에서의 noise 제거는 ISP 이전 단계에서 noise를 제거하는 방식
- ISP에서 RAW 데이터 noise가 있는 상태로 들어가면 얽히고(entangle) 증폭(amplify)됨
- 픽셀 독립적(Pixel-independent) → 공간적 상관(Spatially-correlated) 노이즈로 변화
  - ※ Entangle: ISP의 Demosaicing 과정에서 발생하는데 제거가 더 어려운 형태로 바뀜
  - ※ Amplify: ISP의 gamma correction, tone-mapping 등 과정에서 숨어있는 noise가 두드러짐
  - ✓ 또한 이럴 경우, sharpening과 같은 후처리 작업을 하는데 방해를 함

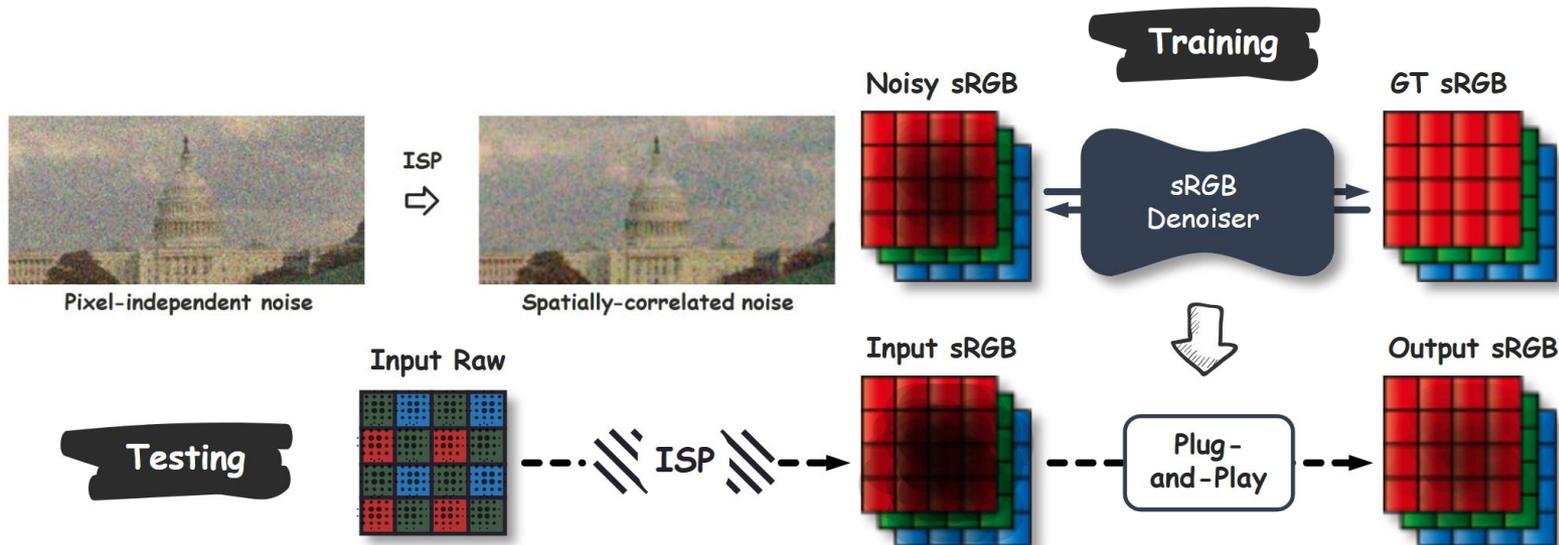


Image processing pipeline with noise

# Background

- **Noise modeling**

- RAW image의 경우 clean image와 noise가 independent한 관계를 가짐

- 즉, ISP를 거치지 않아서 pixel과 noise가 서로 independent한 관계

- $D = I + N_{shot} + N_{DC} + N_{read} + N_{row} + N_q$ 와 같이 정교한 noise modeling이 가능하게 됨

- ※ 여기서  $D$ 는 noise가 있는 이미지,  $I$ 의 경우 noise가 없는 clean 이미지로 가정

- RAW noise-clean GT pair 데이터셋의 경우 제작이 까다롭다는 점 존재

- ※ 또한 데이터 수가 부족해서 성능이 높지 않다는 점 존재

- ※ 아래 결과, 오히려 실제 데이터로 학습한 결과보다 noise modeling을 통해 학습한 결과가 더 좋음

- ✓ 즉, 정교한 noise modeling을 수행할 경우 무한에 가깝게 데이터를 만들 수 있음



29.42/0.519  
Noisy



39.60/0.956  
Noisy-GT 학습 결과



41.18/0.970  
Noise modeling 학습 결과



PSNR/SSIM  
GT

Cao, Yue, et al. "Physics-guided iso-dependent sensor noise modeling for extreme low-light photography." CVPR, 2023.

# Introduction

- Recent learning based image denoising method & noise modeling method

- Physics-based methods

- 해당 방식들은 photo를 digital signal로 변환하는 과정을 번거로운 통계적 모델링을 수행
- 이 방식들은 매우 많은 수의 camera calibration 데이터인 flat-field, bias frame을 필요로 함
  - ⊛ PMN 방식의 경우 각 ISO setting마다 400장의 bias frame을 필요로 함

- Learning-based methods

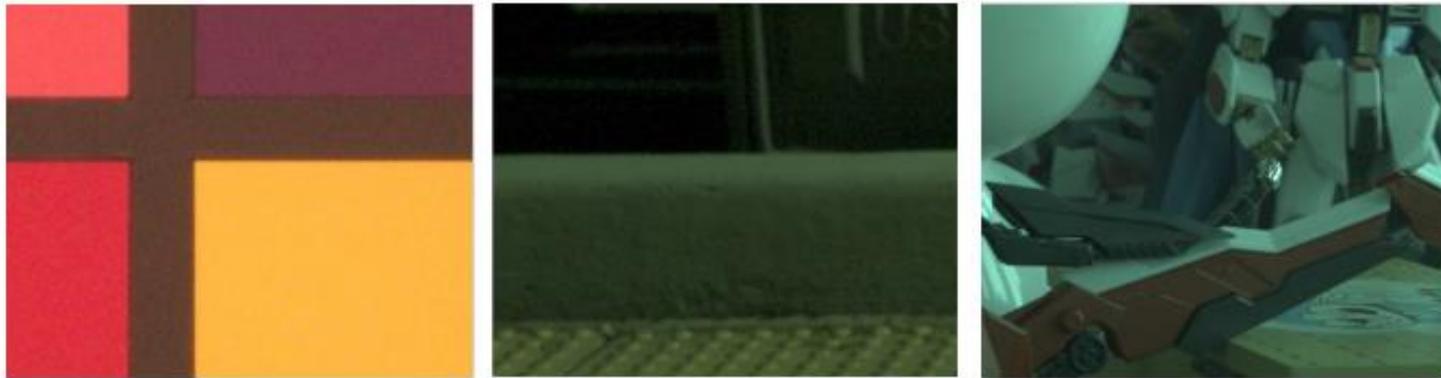
- clean 이미지와 대응되는 noise 이미지 간에 mapping으로 직접적으로 학습하는 방식
  - ⊛ 하지만 해당 방식들의 경우 현재 physics-based statistical method보다 성능이 매우 낮음
  - ⊛ NoiseFlow의 경우 normalizing flow를 사용했지만 striping artifacts, color bias 해결 X
  - ⊛ Starlight는 noise를 clean에 더해 GAN으로 전달, noise가 entangled 되어 noise distribution 추정 X

Method	Category	$N_{shot}$	$N_{FP}$	$N_{BLE}$	$N_{DCSN}$	$N_{read}$	$N_{row}$	$N_q$	Learnability	ISO dependence
ELLE [29]	Physics	✓		✓	✓	✓	✓	✓	None	Incomplete
ELD [31]	Physics	✓		S	✓	✓	✓	✓	None	Incomplete
SFRN [33]	Physics	✓	S	S	S	S	S	✓	None	Incomplete
PMN [9]	Physics	✓	✓	✓				✓	None	Incomplete
NoiseFlow [1]	Learn	✓			✓	✓		✓	Complete	Incomplete
Starlight [25]	Learn	✓	✓		✓	✓	✓	✓	Incomplete	Incomplete
Ours	Learn	✓	✓	✓	✓	✓	✓	✓	Complete	Complete

기존 noise modeling 논문 전략 비교

# Introduction

- Recent denoising dataset problem
  - SIDD dataset
    - 해당 데이터셋은 IIR filter를 이용하여 noise image를 평균을 하여서 GT를 생성
      - ※ 하지만 이럴 경우, black level error noise, fixed-pattern noise가 그대로 남음
  - SID dataset
    - ISO setting을 같게 한 다음 exposure time을 짧게 한 이미지를 noise, 길게 한 이미지를 GT로 생성
      - ※ Long exposure reference에 fixed-pattern noise가 그대로 있음
  - LLD dataset (저자 제안 데이터셋, ELD, DND와 동일)
    - Noisy(short exposure, high ISO), clean(long exposure, low ISO) 이렇게 데이터셋을 구성



기존 denoising dataset (왼쪽부터 SIDD, SID, ELD)

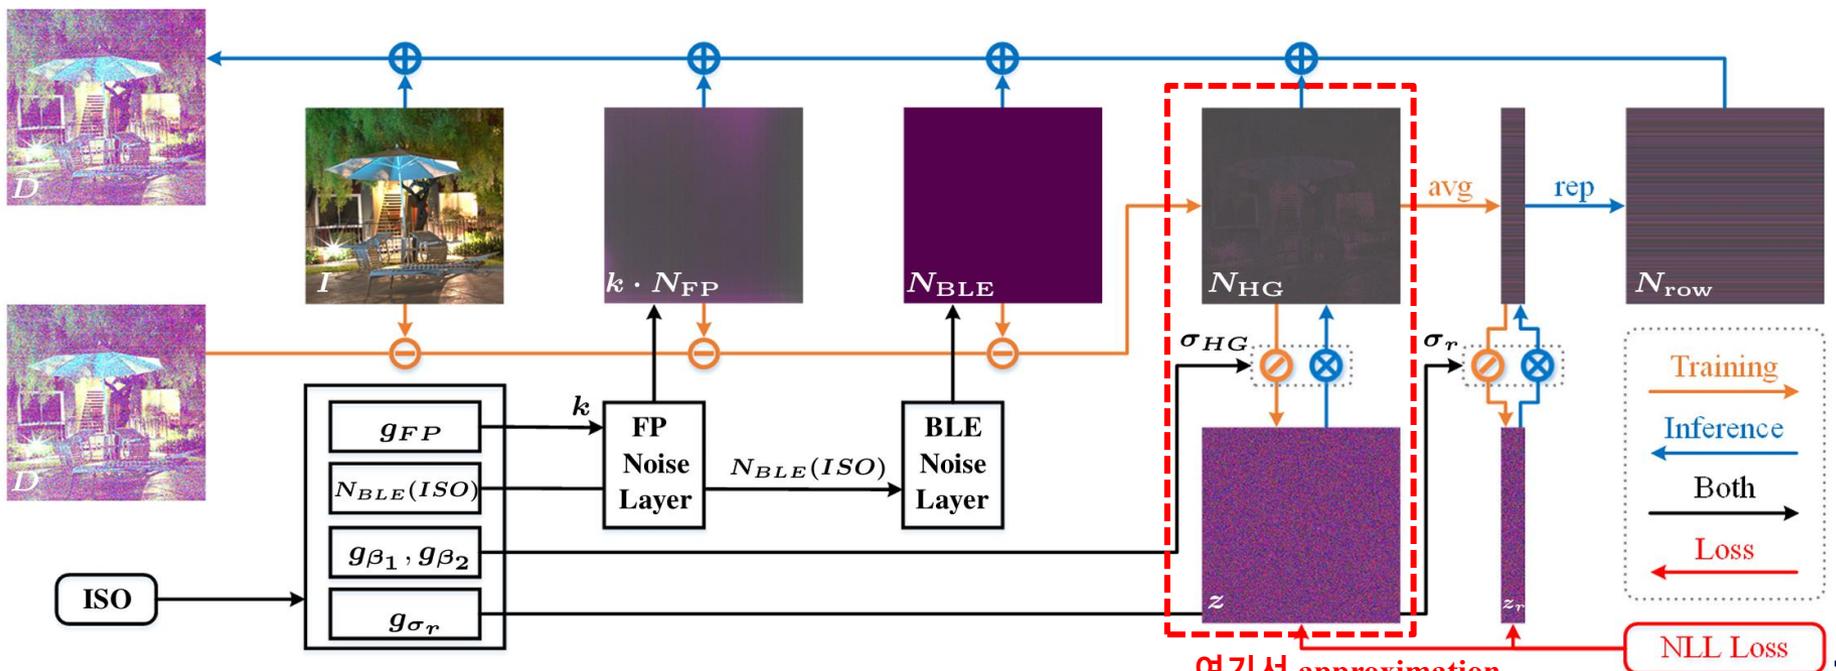
# Method

- Physics-guided Noise Model

- 저자는 다음과 같이 noise modeling을 함:  $D = I + N_{shot} + N_{DC} + N_{read} + N_{row} + N_q$

- Shot noise ( $N_{shot}$ )

- Photon이 들어올 때 물리현상으로 인해 만들어지는 불확실성 때문에 발생
- 전형적으로 Poisson distribution으로 모델링을 하며 system gain(analog, digital)에 의해 control됨
- $N_{shot} \sim P(0, \beta_{shot} \cdot I)$ ,  $N_{shot} \in R^{H \times W}$  이며  $\beta_{shot}$  은 ISO에 따라 달라짐



제안한 noise modeling method

여기서 approximation

NLL Loss

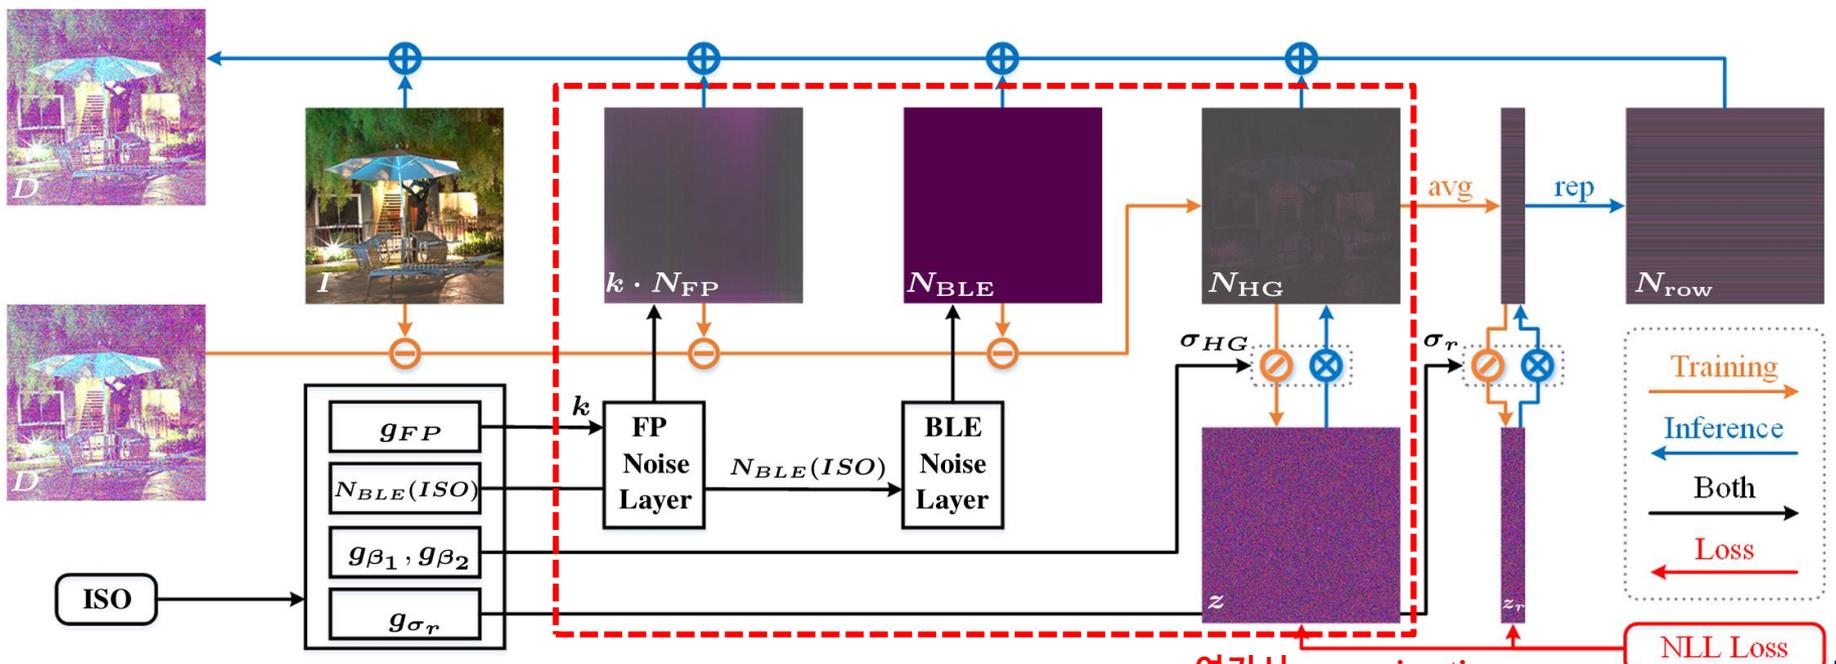
# Method

- Physics-guided Noise Model

- Dark current noise ( $N_{DC}$ )

- Light를 digital signal로 변환, photon에 의해 전류가 산출, sensor에 thermal effect로 인해 dark current
- Thermal effect의 randomness와 ISO dependence, spatial non-uniformity로 인해 모델링 해야함
- $N_{DC} = k \cdot N_{FP} + N_{BLE} + N_{DCSN}$

※  $N_{FP} \in R^{H \times W}$ 는 fixed pattern noise,  $k$ 와  $N_{BLE}$ 는 각각 ISO setting에 따라 선형, 비선형으로 관계



제안한 noise modeling method

여기서 approximation

NLL Loss

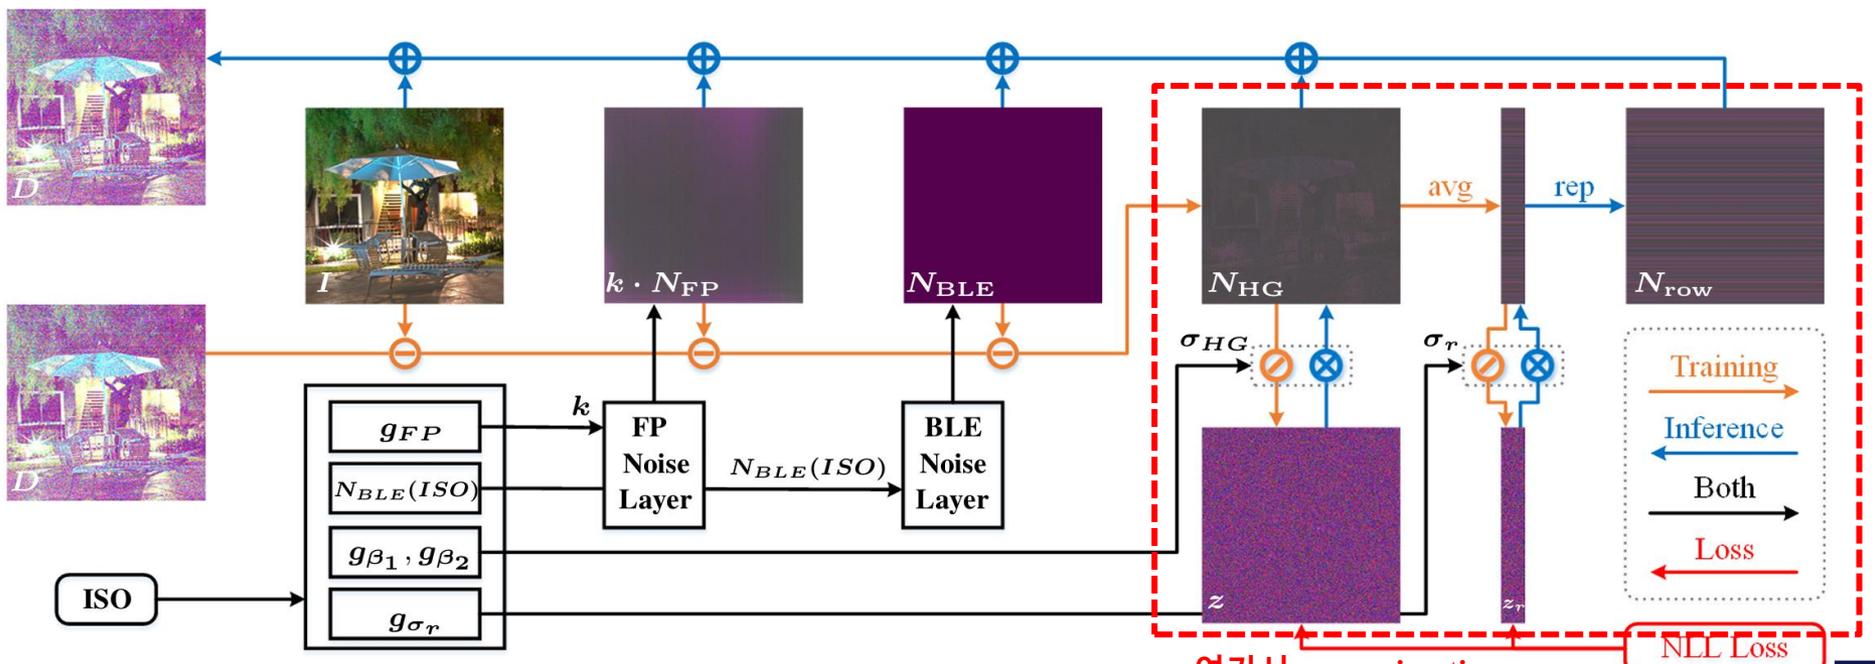


# Method

- Physics-guided Noise Model

- Quantization Noise, Heteroscedastic Gaussian Noise ( $N_q, N_{HG}$ )

- ADC는 signal을 rawRGB 이미지로 저장하기 위하여 이산화를 수행함
- $N_q \sim U(-1/2q, 1/2q)$ , uniform distribution을 근사, 여기서  $q$ 는 저장 이미지의 bit number에 해당
- $N_{shot}, N_{read}$  두 개다 크기  $H \times W$ 를 따르는 Homoscedasticity gaussian distribution으로 근사함
  - \*  $N_{HG} \sim N(0, \beta_1 \cdot I + \beta_2)$ ,  $\beta_1$ 의 경우  $\beta_{shot}$ 에 해당



제안한 noise modeling method

여기서 approximation

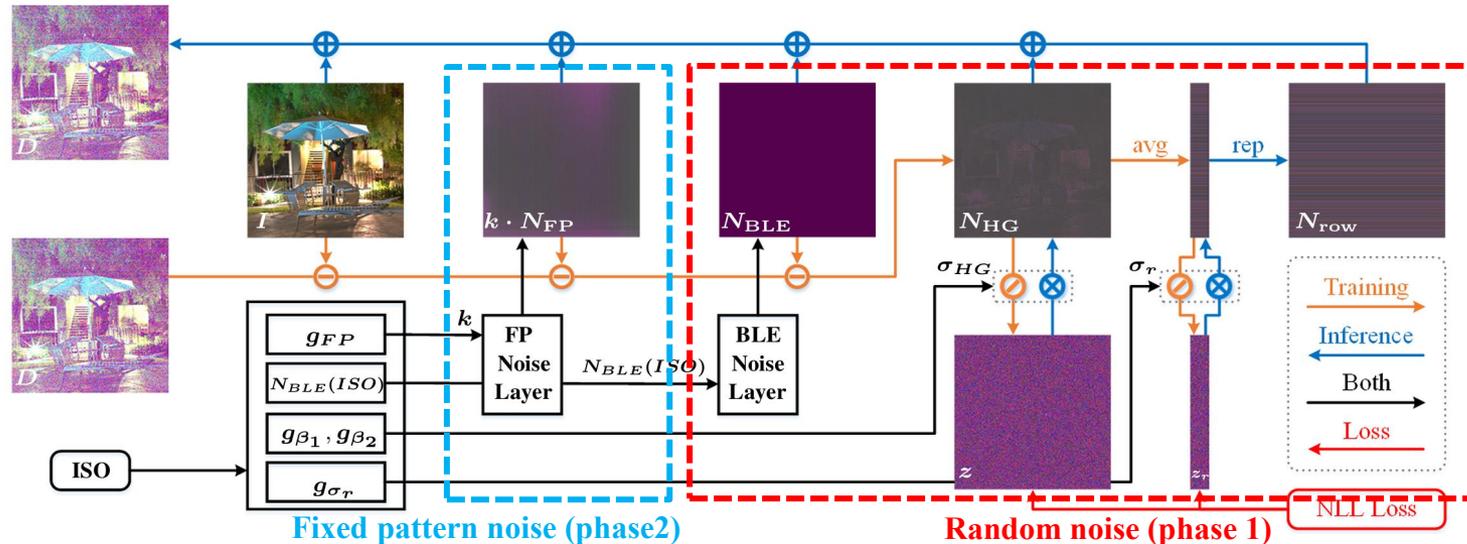
NLL Loss

# Method

$$D = I + \underbrace{k \cdot N_{FP}}_{\text{Fixed-pattern Noise}} + \underbrace{N_{HG} + N_{row} + N_{BLE} + N_q}_{\text{Random Noise}}$$

## • Training strategy

- Noise source는 크게 두 개: fixed-pattern(time-invariant) noise, random(time-variant) noise
- $k \cdot N_{FP}$ 의 선형성은  $N_{BLE}, N_{DCSN}$ 이 제거 되었을 때만 유지가 가능함
  - 따라서 학습 안정성을 위하여 두 단계로 나누어서 학습 진행
    - ※ 1) random noise modeling phase 2) fixed-pattern noise modeling phase
    - ※ Random noise modeling이 끝나면 freeze한 다음 fixed-pattern noise modeling 만 훈련 진행
- Darkshading Correction Strategy:  $N_{FP}, N_{BLE}$ 는 이미 고정이 됨
  - PMN과 동일하게 고정된 노이즈를 우선 빼 다음 denoising(training, inference)을 하는 전략 사용



Fixed pattern noise (phase2)

Random noise (phase1)

제안한 noise modeling method

NLL Loss

# Experiments

- Implementation Details

- rawRGB image (R, Gr, B, Gb)로 packing을 하여 4 channel로 학습 진행

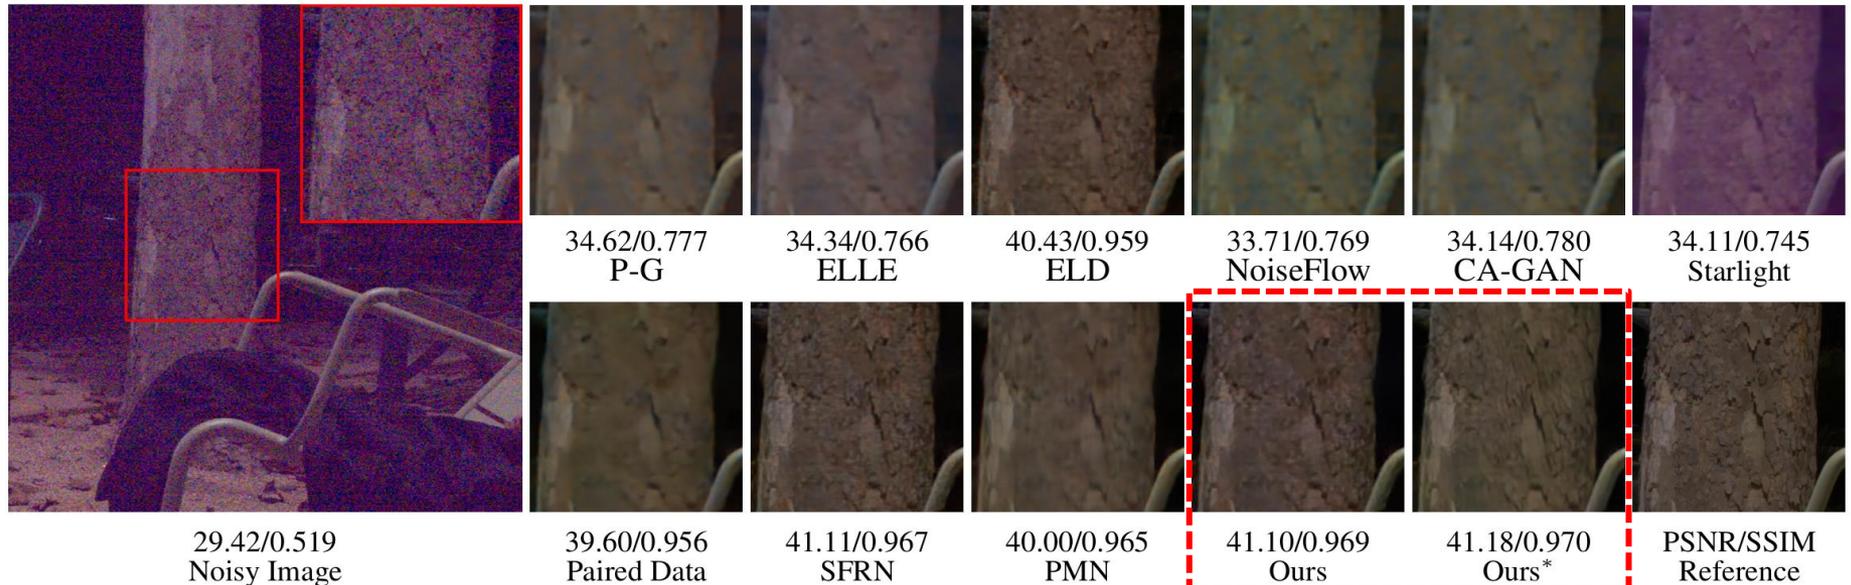
- $g_{fp}, g_{\beta_1}, g_{\beta_2}, g_{\sigma_r}$  은 one-layer MLP 구현,  $N_{BLE}(ISO)$ 의 경우 setting dimensional learnable parameter 구현

- Denoising Stage의 경우 *ours, ours\** 두 개의 결과가 있음.

- *ours*의 경우 모든 clean image에 모든 noise 합성, *ours\** 는 mini-batch를 두 개로 나눠서 학습 진행

- Darkshading correction strategy:  $(D - k \cdot N_{FP} - N_{BLE}(ISO), I)$

- Zero-mean noise strategy:  $(I + N_{HG} + N_{row} + N_q, I)$



Qualitative evaluation 결과

# Experiments

- Comparison with State-of-the-Art

- Noise model의 경우 LLD dataset 가지고 진행, denoising 단계 모두 SID data 및 network 사용
- Evaluation on Sony A7S2 Camera
  - Learning-based method, physical 특성 무시하고 network와 strategy 수행하여 성능 하락 큼
  - Physical model 고려한 starlight 경우 ISO dependence BLE noise 무시, classic modeling 보다 성능 낮음
- Evaluation on Nikon D850 Camera
  - Physics-based method와 비교하여 noise parameter calibration 과정을 생략함
  - 또한 PMN, SFRN 방법 모두 bias, flat field frame을 필요로 하는데 해당 방식은 필요 없다는 장점

Dataset	Ratio	Index	Physics-based			Learning-based				Real noise-based			
			P-G [10]	ELLE [29]	ELD [31]	NoiseFlow [1]	CA-GAN [5]	Starlight [25]	Ours	Paired Data (SID)	SFRN [33]	PMN [9]	Ours*
SID [6]	×100	PSNR	39.03	40.09	41.95	38.89	38.66	40.47	42.10	42.06	42.31	43.16	43.36
		SSIM	0.926	0.931	0.953	0.929	0.921	0.926	0.955	0.955	0.955	0.960	0.961
	×250	PSNR	35.57	36.13	39.44	35.80	35.30	36.25	39.76	39.60	40.18	40.92	41.02
		SSIM	0.861	0.863	0.931	0.867	0.846	0.858	0.933	0.938	0.937	0.947	0.948
	×300	PSNR	32.26	32.54	36.36	32.29	32.02	32.99	36.76	36.85	36.97	37.77	37.80
		SSIM	0.781	0.782	0.911	0.801	0.768	0.780	0.912	0.923	0.915	0.934	0.935
ELD [31]	×100	PSNR	41.76	43.11	45.45	41.05	41.48	43.80	45.61	44.47	45.74	46.50	46.74
		SSIM	0.930	0.940	0.975	0.925	0.933	0.936	0.977	0.968	0.976	0.985	0.986
	×200	PSNR	39.33	40.30	43.43	39.23	39.26	40.86	43.84	41.97	43.84	44.51	44.95
		SSIM	0.872	0.884	0.954	0.889	0.877	0.884	0.959	0.928	0.955	0.973	0.977

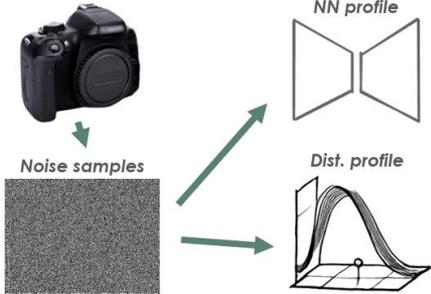
## Quantitative evaluation 결과

Li, Feiran, Haiyang Jiang, and Daisuke Iso. "Noise Modeling in One Hour: Minimizing Preparation Efforts for Self-supervised Low-Light RAW Image Denoising." CVPR, 2025.

# Introduction

- Noise modeling

- Signal-dependent noise 합성하기 위해 균일한 lighting condition에서 system gain calibration
  - Hardware (protocol camera board의 경우 customizing mounting module 필요) setup이 거의 몇 일이 걸림
- Signal-independent noise의 경우 통계적으로 distribution을 정의하는데 어려움
  - 또한 learning based noise profiling 접근 방식의 경우 train하는데 시간이 걸림
- 본 논문의 저자는 denoising performance를 유지하면서 가능한 간단한 noise modeling 제안
  - Signal-independent noise를 정의하는데 불필요한 step을 모두 제거함

Common preparation steps	<p><i>System gain calibration for shot noise (hours to days)</i></p> 	<p><i>Signal-independent noise collection (~one hour) and profiling (≥one day)</i></p> 
	Existing works	<b>Fully required</b>
Ours	<b>Not required</b>	<b>Collection only</b>

Comparing preparation efforts for noise synthesis

# Method

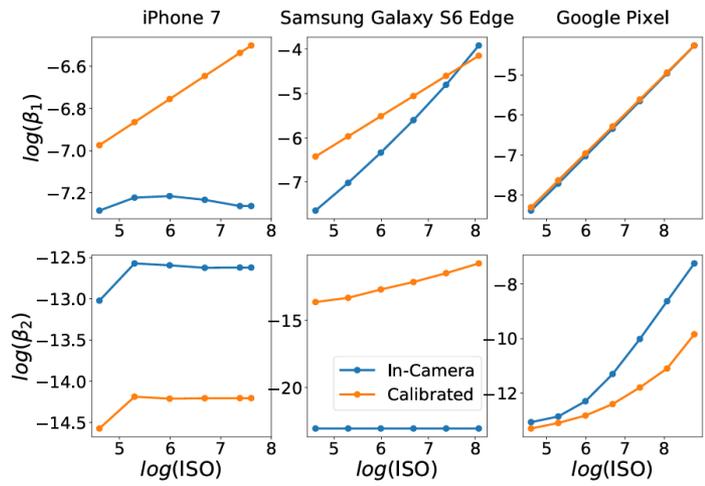
- Image formation model

- Photon에서 digital pixel value 변환 공식  $D = K_d(K_a(X + N_p + N_1) + N_2)$

- Analog-to-digital conversion(ADC)는 공식에서 생략,  $K_d$ 는 digital gain  $K_a$ 는 analog gain,  $X$  photon에 해당
- $N_p$ 는 signal-dependent noise,  $N_1, N_2$ 는 signal-independent noise 각각 ADC 전후 발생 noise

- $K_d=1$ 이라고 가정하면 공식은  $D = \underbrace{K_a(X + N_p)}_{\text{Signal dependent noise}} + \underbrace{K_a N_1 + N_2}_{\text{Signal independent noise}}$

- $N_p$ 의 경우, 빛의 내재된 불확실성과 양자 속성에 의해 유발됨
- $N_1$ 의 경우, 실제로 회로가 동작하기 전에 발생하는 noise (dark-current noise, thermal noise)
- $N_2$ 의 경우, image formatting process가 끝난 뒤 발생하는 noise (banding noise, quantization noise)



Camera 별 signal dependent noise parameter

# Method

- Hypothesizing signal-dependent noise

- $$(X + N_p) \sim P(X) \rightarrow (X + N_p) \sim P(I/K_a) \rightarrow K_a(X + N_p) \sim K_a P(I/K_a)$$

- 해당 방정식은 clean-noise pair에서 shot noise 추정  $\rightarrow$  poisson 분포 추정 및 analog gain scailing

- 평균과 분산:  $E(K(X + N_p)) = K \cdot I/K = I, V(K(X + N_p)) = K^2 \cdot I/K = KI$

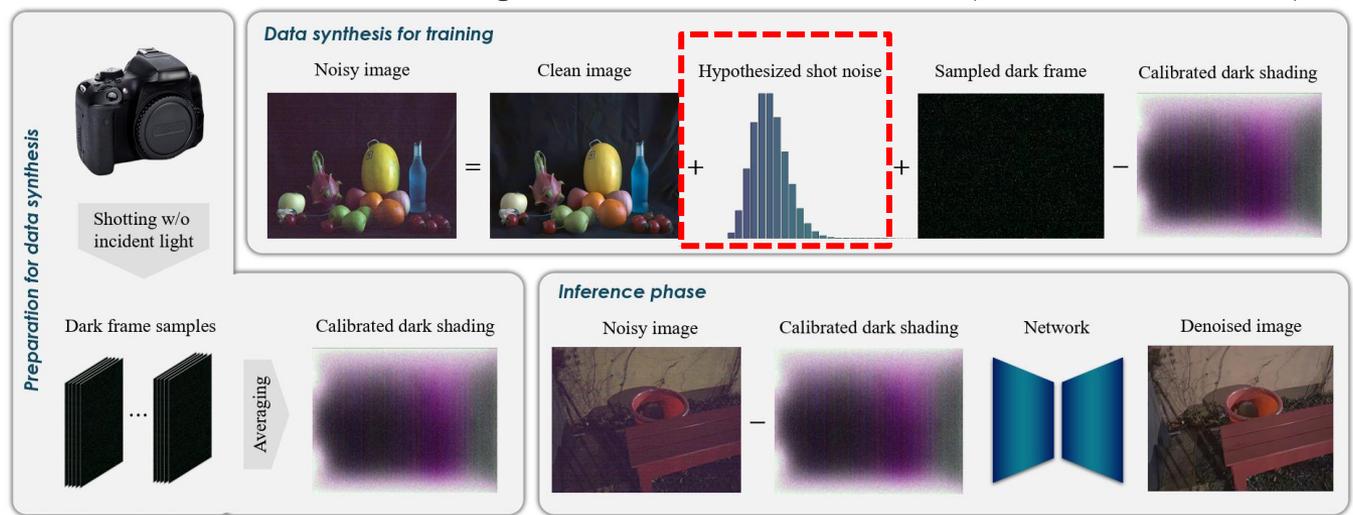
※ 위 식을 통해 평균값은 K와 독립적(노이즈 강도는 K scale)이므로 상대적 bias가 없음을 시사

- 특정 setup에서 가능한 system gain은 매우 작은 범위에 있음

- System gain  $K = QE \times AG$ , Quantum efficiency(QE) analog gain(AG), AG: 사용자 지정 QE: 30~70%

- 이러한 가설을 통해 AG가 주이지면 QE 가정, K를 얻은 뒤 shot-noisy image를 생성

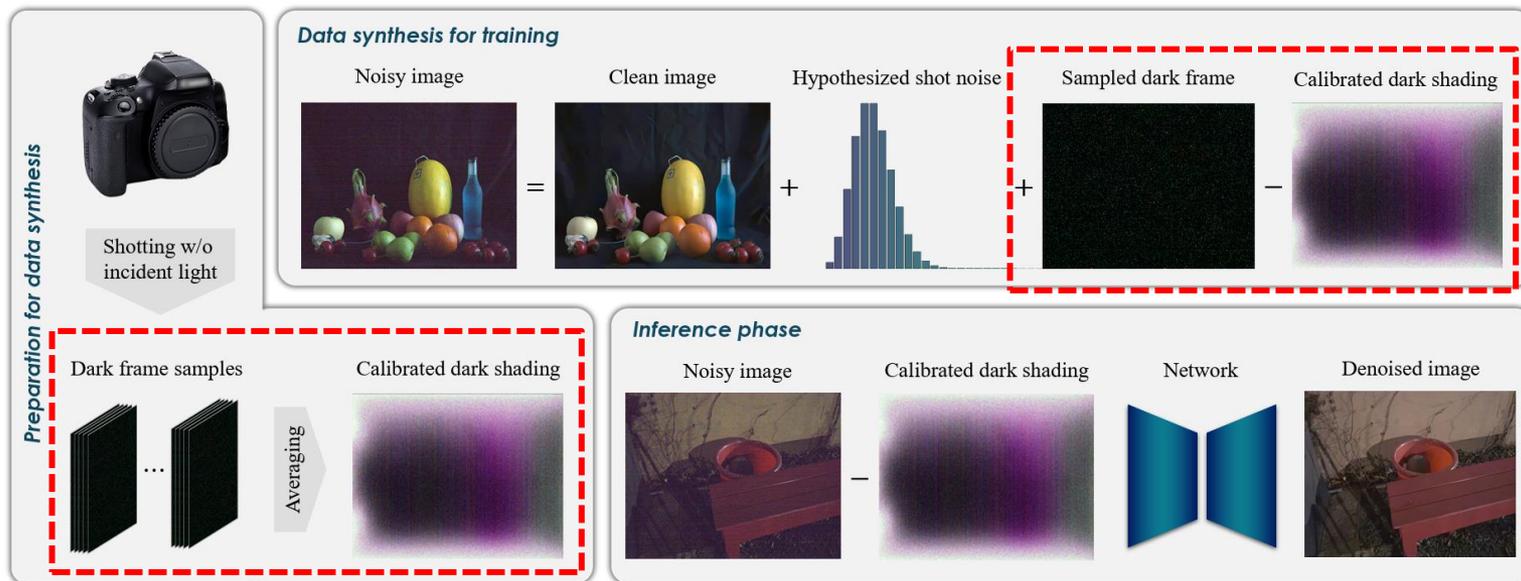
- 직관적으로는 ideal K값을 data augmentation으로도 볼 수 있음 (color bias 방지 가능)



제안한 noise modeling pipeline

# Method

- Sampling signal-independent noise
  - 전반적인 접근 방식은 signal-independent noise의 경우 statistical model을 통해 noise profiling
    - 하지만 이러한 정확한 modeling은 implementation complexity와 bias-variance trade off 존재
  - 따라서 저자들은 sensor에서 얻은 signal-independent noise sample을 직접 적용
    - $k_a N_1 + N_2$  modeling 대신에, target sensor에 dark frame을 여러 장 취득한 뒤, direct sample로 사용
  - 또한 fixed patten noise(temporally consistent noise)를 제거하기 위해 dark shading correction 적용
    - 단순히 앞서 취득한 dark frame을 평균, network에 들어가기 전에 뺀



제안한 noise modeling pipeline

# Experiments

- Comparison methods

- Supervised, Self-supervised, Hybrid method로 나누어서 비교 분석 (모두 같은 U-Net 사용)

- Training and test specifications

- Image와 dark frame 모두  $512 \times 512$  patch로 잘라서 training, L1 loss, data augmentation 사용

- 두 camera (Sony, Nikon) ISO 값에 analog gain 값을 어떻게 encapsulate 했는지 정보 없음

- ※ 하지만 두 카메라의 기본 ISO가 400인 특성을 얹으므로 이것을 AG=1로 설정

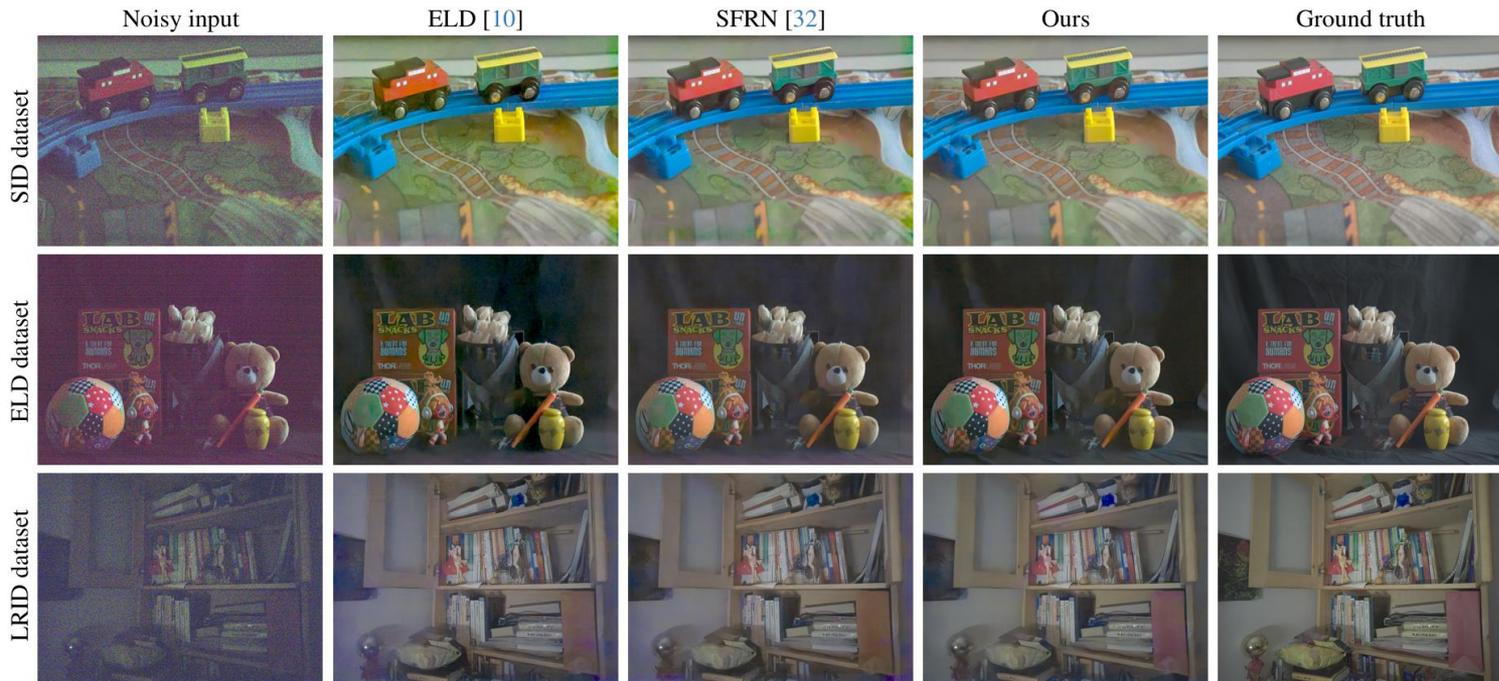
- ※  $K = ISO/100 * 0.1$  근사 등식을 사용하고 QE는 40%라고 가정

Training setup	Method	SID				ELD		
		×100	×250	×300	Avg.	×100	×200	Avg.
Supervised	<b>Paired PMN [4]</b>	42.06 / 0.9548	39.60 / 0.9380	36.85 / 0.9227	39.32 / 0.9374	44.47 / 0.9676	41.97 / 0.9282	43.22 / 0.9479
		43.47 / 0.9606	41.04 / 0.9471	37.87 / 0.9344	40.59 / 0.9465	46.99 / 0.9840	44.85 / 0.9686	45.92 / 0.9763
Hybrid	<b>LED [31]</b> <b>LLD [11]</b>	41.98 / 0.9539	39.34 / 0.9317	36.67 / 0.9147	39.19 / 0.9321	45.36 / 0.9779	42.97 / 0.9577	44.17 / 0.9678
		43.36 / 0.9610	41.02 / 0.9480	37.80 / 0.9350	40.52 / 0.9471	46.74 / 0.9860	44.95 / 0.9770	45.85 / 0.9815
Self-supervised	<b>P-G</b>	39.44 / 0.8995	34.32 / 0.7681	30.66 / 0.6569	34.52 / 0.7666	42.05 / 0.8721	38.18 / 0.7827	40.12 / 0.8274
	<b>ELD [10]</b>	41.95 / 0.9530	39.44 / 0.9307	36.36 / 0.9114	39.05 / 0.9303	45.45 / 0.9754	43.43 / 0.9544	44.44 / 0.9649
	<b>SFRN [32]</b>	42.61 / 0.9580	40.73 / 0.9454	37.64 / 0.9309	40.14 / 0.9438	46.45 / 0.9843	44.58 / 0.9738	45.51 / 0.9790
	<b>NoiseFlow [8]</b>	41.08 / 0.9394	37.45 / 0.8864	33.53 / 0.8132	37.09 / 0.8750	43.21 / 0.9210	40.60 / 0.8638	41.90 / 0.8924
	<b>StarLight [9]</b>	40.47 / 0.9261	36.26 / 0.8575	33.00 / 0.7802	36.33 / 0.8494	43.80 / 0.9358	40.86 / 0.8837	42.33 / 0.9098
	<b>PNNP [13]</b>	<b>43.63 / 0.9614</b>	<b>41.49 / 0.9498</b>	<b>38.01 / 0.9353</b>	<b>40.83 / 0.9479</b>	<b>47.31 / 0.9877</b>	<b>45.47 / 0.9791</b>	<b>46.39 / 0.9834</b>
<b>Ours</b>	<b>43.69 / 0.9618</b>	<b>41.43 / 0.9486</b>	<b>38.06 / 0.9356</b>	<b>40.85 / 0.9478</b>	<b>47.34 / 0.9874</b>	<b>45.51 / 0.9794</b>	<b>46.43 / 0.9834</b>	

Quantitative result 비교

# Experiments

- SID and ELD datasets
  - 매우 간단한 noise synthetic pipeline으로 다른 복잡한 방식보다 뛰어난 결과
  - SOTA supervised method PMN 방식보다 높는데 training할 때 imperfect pixel alignment 문제
- LRID dataset
  - SOTA와 비교하여 0.5dB 높는데, sensor heating과 같은 noise는 modeling이 어려운데, 저자의 방법의 경우 직접 sensor sampling을 하여 이런 결과가 나왔다고 주장



Qualitative result 비교

# References

- Li, Feiran, Haiyang Jiang, and Daisuke Iso. "Noise Modeling in One Hour: Minimizing Preparation Efforts for Self-supervised Low-Light RAW Image Denoising." *Proceedings of the Computer Vision and Pattern Recognition Conference*. 2025.
- Cao, Yue, et al. "Physics-guided iso-dependent sensor noise modeling for extreme low-light photography." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023.
- Wang, Jing, et al. "Rethinking noise modeling in extreme low-light environments." *2021 IEEE International Conference on Multimedia and Expo (ICME)*. IEEE, 2021.
- Wei, Kaixuan, et al. "Physics-based noise modeling for extreme low-light photography." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 44.11 (2021): 8520-8537.

감사합니다.