

OLED Degradation Compensation Using Non-Blind Super-Resolution with Data Counting

Joon-Min Park*, Seon-Yoo Kim*, Gye-Young Kim**

*Student, School of Software, Soongsil University, Seoul, Korea

**Professor, School of Software, Soongsil University, Seoul, Korea

[Abstract]

While Single Image Super-Resolution (SISR) using paired High-Resolution (HR) and Low-Resolution (LR) datasets is effective, obtaining these pairs in real-world scenarios is a challenge. We address this by applying SR to 'Data Counting for OLED Degradation Compensation,' a domain where acquiring such real-world datasets is feasible. This approach uses SR to efficiently reduce the large amount of data required for the counting-based compensation method, which tracks image accumulation to counter OLED deterioration. For our task, we selected the most suitable model and employed a Sequential Up-scaling technique to effectively implement high-magnification SR.

▶ **Key words:** SISR(Single Image Super-Resolution), OLED Compensation, Non-Blind SR, Sequential Up-Scaling, 16x Super-Resolution

[요약]

본 논문은 단일 영상 초해상도를 OLED 열화 보상에 적용하는 새로운 방법을 제안한다. 기존 연구는 고해상도(HR)-저해상도(LR) 쌍 데이터가 필요하지만, 실제 환경에서는 확보가 어렵다. 본 논문은 OLED 전류 누적량 기반 데이터 카운팅 방식을 활용해 HR-LR 쌍을 실세계 조건에서 획득하고, 메모리 절감과 보상 효율 향상을 위한 활용 방안을 제시한다. 고배율 초해상도에서 안정적인 성능을 보이는 SRFBN을 기반으로, 복원 과정을 저배율 단계로 분할해 학습하는 순차적 업스케일링(sequential up-scaling) 전략을 도입하였다. 이를 통해 최대 16배 초해상도를 구현하고 메모리 사용량을 기존 대비 1/256로 줄였으며, 공개 데이터셋과 실제 OLED 열화 실험을 통해 성능을 검증하였다. 제안 모델은 PSNR 54.87, SSIM 0.99라는 우수한 성능을 달성했으며, 특히 복잡한 구조의 데이터셋에서 강점을 보였다. 결론적으로 본 연구는 실세계 HR-LR 기반 초해상도의 가능성을 입증하고, 순차적 업스케일링의 실용성을 확인하였다.

▶ **주제어:** 단일 영상 초해상도, OLED 보상, 비맹목적 초해상도, 순차적 업스케일링, 16배 초해상도

-
- First Author: Joon-Min Park, Corresponding Author: Gye-Young Kim
 - *Joon-Min Park (aura1999@soongsil.ac.kr), School of Software, Soongsil University
 - *Seon-Yoo Kim (tjdn13@soongsil.ac.kr), School of Software, Soongsil University
 - **Gye-Young Kim (gykim11@ssu.ac.kr), School of Software, Soongsil University
 - Received: 2025. 11. 06, Revised: 2025. 12. 14, Accepted: 2025. 12. 23.

I. Introduction

초해상도(Super-Resolution, SR) 기술은 의료 영상 향상, 게임 및 애니메이션 렌더링 등 다양한 분야에서 비용 절감 효과를 입증하며 그 활용 가능성이 지속적으로 확대되고 있다[1][2]. 그러나 실제 응용 환경에서 발생하는 문제의 상당 부분은 열화(Degradation) 과정에 대한 사전 지식이 없거나 HR-LR 데이터 쌍 확보가 어려운 Blind SR에 해당한다. 이로 인해 복원 성능이 기대에 미치지 못하는 한계를 지니며, 특히 복잡하고 불특정한 열화 조건에서는 재현성과 신뢰성이 저하되는 문제가 두드러진다. 반면, 산업 현장과 같이 동일 피사체를 HR과 LR 카메라로 동시 촬영하는 등 제어 가능한 특정 상황에서는 실제 특성을 반영한 HR-LR 쌍 데이터셋을 구축할 수 있다. 이러한 환경에서는 Non-Blind SR 접근이 가능해지며, 열화 조건의 불확실성으로 인한 성능 저하를 근본적으로 방지하고, 주어진 응용 환경에 최적화된 결과를 도출할 수 있는 실질적인 대안이 될 수 있다.

본 논문에서는 제안하는 초해상도(SR) 기술의 효용성을 검증하기 위한 적용 사례로 'OLED 데이터 카운팅 보상(OLED Data Counting Compensation)' 기술을 평가하였다. OLED는 누적 사용 시간에 따라 휘도가 저하되는 열화 현상이 발생하며, 이를 보상하기 위해 픽셀별 누적 사용량을 측정하여 휘도를 보정하는 기술이 사용된다. 디스플레이는 입력 영상의 해상도와 무관하게 패널의 물리적 해상도에 맞춰 각 픽셀에 영상 신호를 전송하므로, 픽셀 단위의 정확한 누적 데이터 수집이 가능하다.

그러나 디스플레이 기술의 발전(고해상도, 고주사율, 고심도)으로 인해 누적 데이터 저장을 위한 요구 메모리 용량이 기하급수적으로 증가하고 있다. 예를 들어, UHD 해상도의 60Hz, 8-bit 영상을 1시간 저장하는 데 약 10GB가 필요하며, 기기 수명(예: 10,000시간) 전체를 고려하면 막대한 저장 공간이 필요하다. 이에 본 논문은 일부 저해상도 화소에서만 데이터를 누적하고, SR 기술로 이를 복원하여 전체 화소를 보상하는 메모리 저감 방식을 제안한다.

이 제안 방식의 특징은 기기에서 누적한 데이터와 별개로 재생한 원본 영상 소스를 확보할 수 있어 Ground Truth(GT)에 해당하는 고해상도(HR) 누적 이미지를 생성할 수 있다는 것이다. 이를 통해 real-world LR-HR 데이터셋을 구축하고 학습 시켜 신뢰도 높은 모델 개발이 가능하다.

기억공간 효율을 극대화하기 위해서는 고배율(high-magnification) SR 기술이 필수적이다. 하지만 주

류 SR 연구는 일반적인 영상의 시각적 품질 향상을 목표로 하며, 주로 저배율(x2, x4) 환경의 성능에 초점을 맞추고 있다. 이로 인해 본 연구의 목표 달성에 필요한 8배 이상의 고배율 SR에 대한 연구는 상대적으로 부족한 실정이다. 일부 연구에서 고배율의 결과를 얻기 위해 저배율 모델을 반복적으로 적용하는 접근법을 사용하지만, 이는 전용 고배율 모델 부재에 따른 차선적 접근일 뿐이다. 특히 고배율 복원 자체의 성능과 효율이 중요한 경우, 이러한 단순 순차 적용 방식은 오차 누적 및 연산량 증가로 인해 상당한 비효율성을 야기한다. 본 논문은 이러한 문제의식에서 출발하여, 누적 영상의 특수성을 고려한 SR 모델을 채택하고, 여기에 효율적인 고배율 복원을 위한 '순차적 업스케일링(Sequential Upscaling)' 전략을 접목하는 새로운 접근법을 제안하고 검증하고자 한다. 이를 통해 기존 방식의 비효율성을 개선하고, 메모리 저감이라는 특정 목표에 최적화된 고배율 SR 기술의 가능성을 제시한다.

II. Preliminaries

1. Related works

1.1 Data Accumulation Strategy for OLED Compensation

누적 전류량은 OLED 열화(degradation)를 결정하는 핵심 인자 중 하나로 알려져 있으며[3][4], 이에 따라 데이터 카운팅(data counting)에 기반한 열화 보상 기법이 활용되고 있다. 그림 1[5]에 도시된 3T1C(3-Transistor 1-Capacitor) 픽셀 회로를 기준으로 데이터 카운팅 기법의 장점을 설명하고자 한다. OLED 열화는 주로 소자의 전류 효율성 저하와 임계 전압(V_{th_oled}) 변이를 유발한다. 기존의 감지(sensing) 기반 보상 방식은 임계 전압 변화를 직접 측정하기 위해 스캔 TFT(SWT)와 감지 TFT(SENT)의 구동 타이밍을 독립적으로 제어해야 하는 복잡한 과정을 필요로 한다. 데이터 카운팅 기반 기법에서는 이러한 물리적 측정 과정이 불필요하며, SWT와 SENT를 개별적으로 구동할 필요가 없다. 이로 인해 두 트랜지스터의 게이트 제어선을 하나의 신호선으로 통합 설계할 수 있다.

회로 구조 단순화는 픽셀 내 비발광 영역을 줄여 개구율을 향상시킨다. 또한 발광 면적 확보를 통해 OLED 소자의 수명을 연장하며, 전압 측정을 위한 Analog-to-Digital Converter(ADC)와 측정용 스위치를 제거함으로써 시스템 복잡성과 비용을 절감한다. 다만, 이러한 접근을 위해서는 데이터 누적용 별도의 메모리가 요구된다.

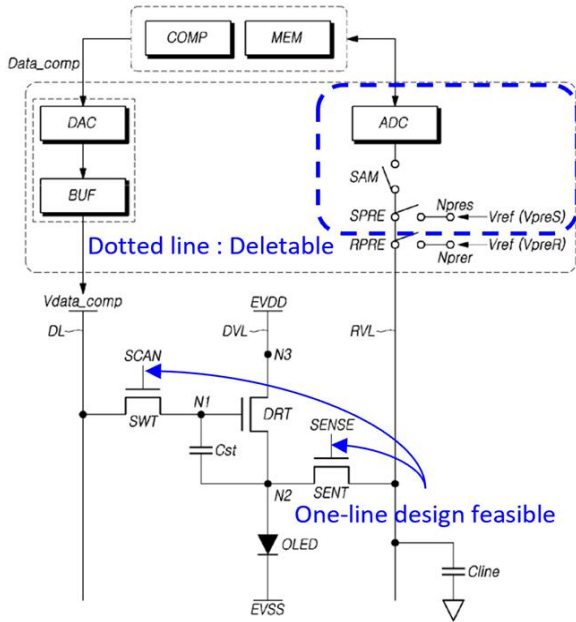


Fig. 1. Schematic of a 3T1C OLED display circuit [5]

데이터 카운팅 기법에서 요구되는 메모리 용량은 디스플레이 해상도 및 주사율에 따라 증가한다. 예를 들어, 일반적인 압축률을 적용한 UHD 60Hz 영상은 시간당 약 10GB의 저장 공간을 필요로 한다. 이는 제품의 전체 수명 (약 10,000시간)을 고려할 때 약 100TB라는 막대한 규모로, 실질적인 시스템 적용에 있어 큰 비용적·물리적 부담으로 작용한다. 따라서 본 논문은 데이터 카운팅 기법에 초해상도(SR) 기술을 접목하여, 이러한 메모리 요구량을 효율적으로 절감하는 방안을 제안하고 검증하는 것을 목표로 한다.

1.2 Criteria for Model Selection

데이터 카운팅 기법에 적용되는 초해상도 성능은 누적 이미지의 통계적 특성에 의해 결정된다. 실제 환경에서는 이미지가 지속적으로 누적되지만, 그림 2에 나타난 바와 같이 ImageNet 데이터셋 40만 장 누적 시점에서 SR 성능이 포화되는 것으로 관찰되었다. 이는 본 연구에서 구축한 100만 장 규모 데이터셋이 무한 누적 상황의 통계적 특성을 근사하며, 성능 평가를 위한 유효한 벤치마크 역할을 수행함을 보여준다. 추가적으로, 누적 이미지 내 ‘로고’와 같은 고정 패턴의 영향을 분석하기 위해 식 (1)의 람다(λ) 계수를 통해 패턴 강도를 제어하며 SR 성능을 비교 평가했다 (그림 3).




Fig. 2. PSNR trend with respect to the number of accumulated images using the SRFBN model

$$I_{\text{평균 이미지}} = \lambda I_{\text{고정 pattern}} + (1 - \lambda) I_{\text{누적 이미지}} \dots (1)$$

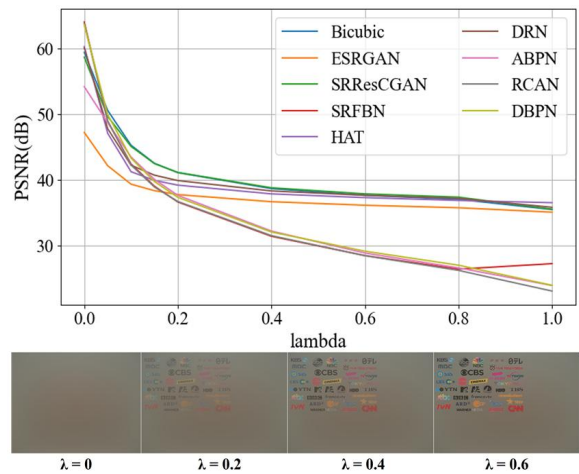


Fig. 3. Comparison of x4 SR performance on one million accumulated ImageNet images and the ‘logo’ image for different λ coefficients[6][7][8]

본 논문이 다루는 누적 영상 초해상도 기술은 일반적인 SR과 달리, 디스플레이 열화 보상이라는 특수 목적을 가진다. 따라서 모델 선정 시 PSNR과 같은 일반 지표를 넘어, 휘점(bright spot), 암점(dark spot), 줄무늬 등 디스플레이 하드웨어 결함으로 오인될 수 있는 시각적 이상 현상(artifacts) 억제 능력이 핵심 평가 기준이 된다. 이러한 결함은 GT와의 절대 오차(L1 distance)가 큰 이상치(outlier) 픽셀에 의해 발생하는 경향이 있다. 주요 모델들을 비교 분석한 결과, SRFBN 모델이 이러한 특성에서 가장 적합하였다. SRFBN은 고정된 ‘로고’ 패턴의 강도가 증가할 경우 PSNR 성능이 다소 저하되는 경향이 관찰되었으나, 그림 4에서 나타난 바와 같이 다른 경쟁 모델 대비 아티팩트(artifact) 발생이 현저히 낮았다. 또한 그림 5에서 볼 수 있듯이, 치명적인 휘/암점의 원인이 되는 L1 오차 이상치 분포 역시 가장 낮았다.




Fig. 4. Comparison of x4 SR artifacts for the 'logo' pattern ($\lambda = 1$) across different models[9][10][11][12]




Fig. 5. L1 value distribution across models

결론적으로 현재 S.O.T.A 모델이 transformer 기반 모델임에도 불구하고, 본 연구의 특수성을 고려하여 최종 적용 환경에서 발생할 수 있는 치명적 오류를 최소화하고 안정적인 결과를 제공하는 모델로 SRFBN[11]을 선정하였다. SRFBN은 피드백 구조를 기반으로 다단계 복원 과정을 반복적으로 수행함으로써, 고배율 초해상도에서도 비교적 안정적인 수렴과 우수한 시각적 품질을 보인다.(그림 6) 특히 반복적인 피드백 과정에서 이전 단계의 복원 정보를 재활용함으로써 고주파 성분 손실이 억제되고, 픽셀 간 불연속성이 감소하는 경향이 보인다. 이러한 특성으로 인해 L1 값이 낮게 분포하며, 블러링 및 링잉(ringing)과 같은 아티팩트(artifact) 발생이 상대적으로 낮게 관찰되었다. 이는 본 연구의 목적과 부합하는 결과로 판단된다.

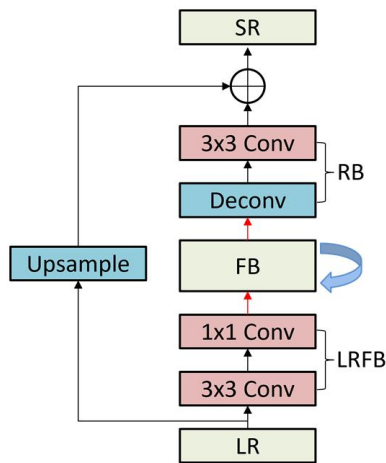


Fig. 6. SRFBN model [11]

III. The Proposed Scheme

1. Method

1.1 Sequential Up-scaling SRFBN Architecture

본 논문의 핵심 목표는 메모리 사용량을 획기적으로 절감하기 위해 고배율 초해상도(Super-Resolution, SR)를 구현하는 것이다. 그러나 SR의 배율이 증가할수록 저해상도(LR) 이미지의 정보량이 극도로 적어져 복원이 어려워지는 trade-off 관계가 존재한다(그림 7).




Fig. 7. Images obtained by successively reducing a 16x16 binary image by half at each step

고배율 초해상도(SR)의 구현에서 발생하는 저해상도(LR) 입력의 정보 부족 문제를 해결하기 위해, 본 연구에서는 SRFBN을 기본 모델로 사용하는 단계별 학습(Stage-wise Learning) 전략을 제안한다. 이 전략은 x16 복원 과정을 여러 저배율 단계로 분할하고, 각 단계를 개별적으로 최적화하는 접근법이다. 첫 번째 방식은 각 복원 단계(예: 1/16 LR → 1/8 LR)를 독립적인 모듈로 간주하고, 원본 고해상도(HR) 이미지로부터 생성된 명확한 Ground Truth(GT)를 사용하여 개별적으로 학습시키는 독립 학습 방식이다(그림 8). 이에 비해 순차 종속 학습 방식(그림 9)은 이전 단계의 SR 결과물을 다음 단계의 입력으로 사용하는 방법으로, 실제 오류 전파 상황을 더 잘 반영할 것으로 기대했다. 그러나 표 1에 명시된 바와 같이, 모델 1은 각 단계에서 중간 해상도 GT(Ground Truth)를 직접 참조하여 학습하므로 타겟 해상도와 차이가 일정하나, 모델 2는 오차를 포함한 하위 해상도 영상을 입력받아 더 큰 해상도 격차를 복원해야 하므로 Step 2부터 복원

성능(PSNR/SSIM)이 모델 1대비 저하됨이 확인 되었다.

또한 표 2에 나타난 바와 같이, 모델 1은 다양한 벤치마크 데이터셋에서도 모델 2를 상회하는 결과를 보여줌으로써 제안하는 학습 전략의 범용성과 우수성을 입증하였다.

따라서 본 논문을 단계 별 학습 아키텍처(모델 1)을 중심으로 연구 하였으며, 이를 SU-SRFBN (Sequential Up-scaling SRFBN) 또는 간략히 SU로 명명한다.




Fig. 8. Step-by-step independent training (Model 1)




Fig. 9. Training using the previous stage's output as the input (Model 2)

Table 1. Step-wise PSNR and SSIM results on BSD100

	Model 1		Model 2		
	PSNR	SSIM	PSNR	SSIM	
BSD100	Step 1	31.31	0.636	31.31	0.636
	Step 2	24.07	0.501	19.88	0.427
	Step 3	21.49	0.447	18.60	0.405
	Step 4	21.20	0.441	18.30	0.399

Table 2. x16 SR comparison between Model 1 and 2

	Model 1		Model 2	
	PSNR	SSIM	PSNR	SSIM
BSD100	21.20	0.441	18.30	0.399
MANGA109	18.28	0.568	15.86	0.516
Urban100	18.25	0.424	15.31	0.360
DIV8k	26.78	0.691	23.47	0.654
DIV2k	22.08	0.562	18.76	0.506

제안된 모델 1(SU)의 단계별 성능을 평가하기 위해, 이진(binary) 이미지를 대상으로 기본 모델인 SRFBN과 비교 분석을 수행했다 (그림 10). 평가를 위해 Ground Truth(GT) 영상으로부터 바이큐빅 보간법을 이용해 1/2 씩 순차적으로 저해상도(LR) 영상을 생성했으며, 각 단계 별 복원 결과에 대해 PSNR을 측정했다.




Fig. 10. PSNR results for x2 scaling

단계별 업스케일링 과정에서, 초기 복원 단계에서는 SRFBN이 이미지의 전체 구조(structure)를 비교적 안정적으로 유지하는 특성을 보였으나, 미세 질감(texture) 복원 능력은 상대적으로 제한적이었다. 반면, 제안 모델은 모든 단계에서 PSNR 측정 결과 SRFBN을 상회하며, 구조와 질감을 균형 있게 복원함을 확인하였다. 그림 11와 12의 혼합 구성 평가 결과, 최종 결과물의 특성은 초기 복원 단계에서 사용된 모델의 영향에 크게 의존하는 것으로 나타났다. 예를 들어, 구조적 복원력이 강한 SRFBN을 초기 단계에 적용하면, 후속 단계에서 다른 모델을 사용하더라도 전체 결과물에 구조적 특성이 유지되었다.




Fig. 11. PSNR for x4 scaling using a mixed model




Fig. 12. BSD dataset result using a mixed model




Fig. 13. Performance comparison by cell unit size for x16 SR

이러한 해상도 의존성은 특히 정보가 희소한 초기 단계에서 이미지 특징이 복원되는 방식이 최종 결과의 특성에 영향을 미칠 수 있음을 시사하며, 이는 입력 해상도에 따라 모델의 특징 맵이 상이하게 형성되는 현상과 관련될 수 있다. 이러한 요인은 배울 정보를 사전에 알 수 없는 Blind SR 환경에서 성능 저하의 주요 원인 중 하나로 작용할 가능성이 있다. 이에 본 논문에서는 고정된 x16 배율을 목표로 설정하고, x2 및 x4 모델의 앙상블 조합에 대한 단계별 성능을 체계적으로 평가함으로써 최적의 순차적 업스케일링 구조를 탐색하였다.

1.2 Resolution-Performance Analysis

제안 모델(SU)과 기본 모델(SRFBN)의 16배 초해상도(SR) 성능을 다양한 구조적 패턴을 포함하는 이진(binary) 이미지 데이터셋을 통해 비교 분석하였다(그림13). 해당 데이터셋은 320x320 픽셀 내에 1x1부터 160x160까지 다양한 크기의 셀 유닛(Cell Unit)을 무작위로 배열하여 생성했으며, Ground Truth(GT)로부터 바이큐빅 보간법을 통해 1/16 스케일의 저해상도(LR) 이미지를 생성하여 평가에 사용했다. 제안 모델(SU)은 x2 스케일 모델을 단계별로 순차 학습하여 x16 배율을 구현한 반면, SRFBN은 단일 x2 모델을 네 번 반복 적용하는 방식을 사용했다.

그림 13의 시각적 결과 비교에서, 두 모델은 뚜렷한 차이를 보였다. SRFBN은 모든 해상도에서 일관된 강한 구조적 복원 특성을 보였다. 그러나 입력 영상 해상도와 관계없이 유사한 크기의 구조를 유지하려는 특성이 있으며, 특히 저해상도 패턴(큰 셀 단위)에서는 아티팩트(artifact)가 발생하는 경향이 나타났다. 이는 단일 특징 맵을 단계

별 학습 없이 반복 적용할 때 발생하는 부작용으로 분석된다. 반면, 제안 모델(SU)은 저해상도 영상에서 라운딩(rounding) 현상이 나타나며 상대적으로 부드러운 복원 결과를 보였다. 즉, 전반적인 형태는 유지하지만 세밀한 구조를 복원하는 특성은 상대적으로 약하게 나타난다. 이러한 시각적 특성은 그림 14의 정량적 PSNR 평가 결과에서도 확인된다. 제안 모델(SU)은 단계별 학습 전략을 채택했음에도, 학습이 범용 벤치마크 데이터셋에 기반했기 때문에 특정 패턴을 가진 평가 데이터셋의 모든 해상도에서 우위를 점하지는 못했다. 특히 16x16 이하의 미세한 셀 단위에서는, 강한 구조 복원력을 지닌 SRFBN이 오히려 더 높은 PSNR을 기록하는 한계를 보였다. 이처럼 특정 해상도 구간에서 나타나는 성능 저하 및 모델 간 성능 교차 현상은 학습 데이터와 평가 데이터 간 통계적 특성 차이에서 기인하는 것으로 판단된다.

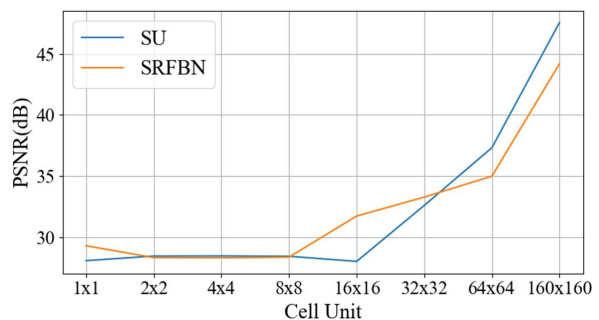


Fig. 14. PSNR results for SR performance evaluated at different resolutions

2. Experiment

2.1 Experiment Setup

모델의 성능 평가는 공개 벤치마크 데이터셋을 활용하여 이루어졌다. 고정된 패턴의 영향을 분석하는 누적 영상 실험에는 ImageNet 1M 데이터가 배경으로 사용되었다. 또한, 실제 환경에서의 성능을 검증하기 위해 OLED 패널을 6500시간 동안 연속 구동하여 가속 열화 테스트 데이터를 구축했다. 또한 평가에 사용될 저해상도(LR) 영상은

원본 고해상도(HR) 영상으로부터 OpenCV 라이브러리의 바이큐빅 보간법(bicubic interpolation)을 적용하여 생성하는 것을 기본으로 하였다. 기존 연구와의 성능 비교 과정에서 발생한 불일치를 확인하기 위해 Pillow 라이브러리를 사용한 추가 검증도 진행했다.

2.2 Benchmark Evaluation Results

그림 15는 BSD100과 DIV2K 등 벤치마크 데이터셋에




Fig. 15. x16 SR results of different models on the Urban100 and DIV2K datasets

Table 3. x8 and x16 SR results via Ensemble Configurations (Proposed)

1-1: SUx2 → SUx4, 1-2: SUx2 (Steps 1→2→3), 2-1: SUx4 (Steps 1→2), 2-2: SUx2 (Steps 1→2→3→SRFBNx2), 2-3: SUx4 (Step 1→SUx2 Step 3→SRFBNx2) [13-20]

Algorithm	Scale	Set5		Set14		BSD100		Urban100		Manga109	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DBPN	x8	19.93	0.538	18.49	0.461	19.10	0.449	16.17	0.405	17.40	0.546
RCAN		19.41	0.526	18.23	0.442	18.76	0.438	15.76	0.388	17.00	0.522
ABPN		19.36	0.524	18.55	0.455	18.33	0.427	16.23	0.430	17.64	0.582
SRFBN		19.94	0.533	18.48	0.456	19.01	0.440	15.90	0.402	17.31	0.557
Ours 1-1		24.67	0.675	22.80	0.558	23.08	0.518	20.41	0.535	21.15	0.679
Ours 1-2		24.70	0.676	22.81	0.559	23.08	0.518	20.43	0.536	21.16	0.678
		DIV8K val		DIV2K val		BSD100		Urban100		Manga109	
DBPN	x16	-	-	17.65	0.466	17.28	0.366	14.30	0.312	14.98	0.444
RCAN		21.60	0.612	16.94	0.441	16.66	0.345	13.66	0.291	14.40	0.417
ABPN		22.38	0.638	17.76	0.480	16.23	0.313	14.78	0.310	16.71	0.411
SRFBN		22.13	0.629	17.44	0.462	17.12	0.363	14.08	0.312	14.85	0.455
Ours 2-1		26.78	0.691	22.08	0.562	21.20	0.441	18.25	0.424	18.28	0.568
Ours 2-2		26.68	0.684	22.03	0.554	21.15	0.433	18.22	0.414	18.27	0.558
Ours 2-3		26.78	0.691	22.08	0.561	21.21	0.441	18.26	0.424	18.29	0.568

적용된 x16 초해상도 모델의 결과를 보여준다. 1/16 LR 이미지는 원본 이미지로부터 OpenCV의 바이큐빅 보간법을 이용해 생성했다. 제안 모델을 제외한 비교 대상 모델들은 연속 x4 적용(cascaded x4 SR) 방식을 사용하여 결과를 산출하였다. 그림에서 확인할 수 있듯이, 기존 모델들은 원본에 없는 심각한 왜곡(distortion)이나 아티팩트(artifact)를 생성하는 경향을 보였다. 반면, 제안 모델은 약간의 블러링(blurring)은 관찰되나 이러한 심각한 왜곡은 효과적으로 억제했다. 이는 앞서 해상도별 평가에서 확인된 바와 같이, 초기 저해상도 단계의 안정적인 학습이 최종 결과 품질 향상에 기여했을 것으로 판단한다.

표 3은 다양한 데이터셋에 대한 x8 및 x16 배율의 초해상도 결과를 제시한다. 제안 모델은 PSNR과 SSIM 지표 모두에서 기존 모델들보다 일관되게 우수한 성능을 보였으며, 특히 복잡한 기하학적 구조를 포함하는 Urban100, DIV8K와 같은 데이터셋에서 성능 향상 폭이 두드러졌다.

그러나 실험 과정에서 기존 모델들의 성능이 문헌에 보고된 수치와 본 연구의 재현 결과 사이에 불일치가 존재함을 확인하였다. 이러한 불일치는 LR 데이터셋 생성 시 열화 과정(degradation process)의 차이에 기인한 것으로

가정하고, Pillow 라이브러리의 바이큐빅 보간법을 적용하여 LR 이미지를 새로 생성한 뒤 x16 결과를 재검증하였다(표 4). 그 결과 기존 모델들의 성능이 일부 향상됨을 확인했으며, 이러한 조건에서도 제안 모델은 여전히 경쟁력 있는 높은 성능을 유지했다. 이 결과는 열화 과정이 SR 성능에 미치는 중요한 영향을 보여주며, HR-LR 데이터셋의 관계가 명확한 실제 시나리오(real-world scenario) 환경에서 제안하는 단계별 학습 방식의 효과적임을 입증한다.

2.3 Accumulated image Experiment

고정 패턴이 없는 이상적인 환경에서는 모든 모델이 OLED 보상에 대해 유사하게 높은 효율로 SR을 수행할 수 있다. 그러나 실제 OLED 열화는 주로 고정된 패턴이 빈번하게 발생하는 영역에서 나타나므로, 이를 반영한 실험 설계가 필요하다. 본 연구에서는 세 가지 시나리오, 즉 (1) 고정 패턴이 없는 경우, (2) 강한 단일 고정 패턴이 존재하는 경우, (3) 유사한 위치에 혼합된 고정 패턴이 발생하는 경우에 대해 실험을 수행하였다. 실험 2와 3에서는 고정 패턴의 강도에 따른 SR 성능을 평가했으며, 패턴에 할당된 가중치를 람다(λ) 값으로 표현하여 결과를 분석하였다.

Table 4. Average PSNR/SSIM values at $\times 16$ scale using Pillow bicubic interpolation

Algorithm	Scale	DIV8k val		DIV2k val		BSD100		Urban100		Manga109	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DBPN		-	-	-	-	23.02	0.469	20.25	0.463	21.13	0.631
RCAN		28.69	0.709	24.44	0.597	23.02	0.470	20.32	0.465	21.11	0.632
ABPN	x16	28.69	0.711	24.49	0.598	20.83	0.417	19.45	0.429	17.49	0.446
SRFBN		28.65	0.709	24.41	0.595	23.00	0.468	20.31	0.467	21.08	0.631
Ours		27.35	0.682	22.99	0.550	22.02	0.432	19.06	0.402	19.34	0.549

Table 5. x16 performance evaluation across three scenarios: clean, single logo, and mixed logos

	accumulate Number	ABPN		DBPN		SRFBN		RCAN		Ours(x4x4)	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Accumulation of basic ImageNet images	1K	27.63	0.935	46.49	0.986	46.59	0.987	46.48	0.986	48.35	0.988
	10K	26.69	0.942	55.36	0.997	55.26	0.997	55.21	0.997	55.95	0.998
	100K	26.86	0.943	57.84	0.999	57.82	0.999	57.71	0.999	58.50	0.999
	300K	26.78	0.943	58.36	0.999	58.45	0.999	58.34	0.999	58.87	0.999
	500K	26.83	0.944	58.33	0.999	58.35	0.999	58.24	0.999	58.87	0.999
	700K	26.74	0.943	58.50	0.999	58.52	0.999	58.41	0.999	58.99	0.999
	900K	26.89	0.943	58.35	0.999	58.40	0.999	58.34	0.999	58.92	0.999
	1M	26.93	0.943	58.24	0.999	58.27	0.999	58.19	0.999	58.68	0.999
	blending lambda										
Single logo blended with ImageNet 1M accumulated image	0.00	26.93	0.943	58.24	0.999	58.27	0.999	58.19	0.999	58.68	0.999
	0.05	25.90	0.946	55.75	0.997	56.08	0.997	55.72	0.997	57.22	0.998
	0.10	25.58	0.944	51.39	0.994	51.81	0.994	51.37	0.993	54.68	0.996
	0.15	25.55	0.939	47.47	0.988	47.98	0.987	47.12	0.984	52.13	0.994
	0.20	25.57	0.933	44.77	0.981	45.44	0.981	44.35	0.976	49.96	0.991
	0.60	25.30	0.887	36.05	0.931	36.19	0.938	34.28	0.916	40.68	0.966
	1.00	26.42	0.938	31.82	0.894	32.10	0.909	29.89	0.876	36.18	0.947
Complex logo blended with ImageNet 1M accumulated image	0.00	26.93	0.943	58.24	0.999	58.27	0.999	58.19	0.999	58.68	0.999
	0.05	26.92	0.943	58.00	0.999	58.05	0.999	57.98	0.999	58.43	0.999
	0.10	26.91	0.943	57.75	0.999	57.85	0.999	57.79	0.999	58.12	0.999
	0.15	26.92	0.944	57.11	0.998	57.19	0.998	57.18	0.998	57.70	0.999
	0.20	26.85	0.944	56.45	0.998	56.57	0.998	56.51	0.998	57.10	0.998
	0.60	26.53	0.942	51.08	0.995	51.45	0.995	51.16	0.995	52.47	0.995
	1.00	24.87	0.865	47.11	0.989	47.33	0.990	47.08	0.989	48.93	0.991

고정 패턴 평가는 ImageNet 1M 누적 이미지를 배경으로 한 테스트 이미지를 활용하였다. 표 5의 결과에 따르면, 제안 모델은 모든 실험에서 일관되게 우수한 성능을 나타냈다. 특히 가장 도전적인 조건인 단일 로고 실험에서, 제안 모델은 아티팩트(artifact)의 발생을 억제하면서도 가장 높은 PSNR을 달성한 것으로 그림 16에서 확인된다. 이러한 결과에서도 순차적 업스케일링의 보수적 복원 경향이 뚜렷하게 확인된다. 로고의 가장자리는 다른 모델에 비해 상대적으로 부드럽게 복원되었지만, 링잉 아티팩트(ringing artifact)는 생성되지 않았다.

2.4 OLED Panel Experiment

그림 17은 실제 OLED 패널의 열화 보상 실험 결과를 보여준다. 패널의 열화를 유도하고 평가하기 위해, 고정 패턴을 포함한 4시간 분량의 비디오를 6500시간 동안 연속 재생하였다. 이 과정에서 전체 구동 시간에 대한 Ground Truth(GT) 누적 이미지를 직접 생성했으며, 초해상도(SR) 평가에 사용될 저해상도(LR) 이미지는 GT를 1/16 바이큐빅 다운샘플링 하여 획득하였다. 실제 패널에

서는 열화가 육안으로 뚜렷하게 관찰되었으나, 촬영된 영상에서는 그 차이를 구별하기 어려웠다.

결과 비교의 명확성을 위해, 원본 이미지와 시각적 강조 처리를 거친 영상을 그림 17에 함께 제시하였다. 데이터 카운팅 기반 보상은 OLED 열화가 누적 전류량 외의 복합적인 요인에도 영향을 받기 때문에 완벽한 보상을 구현하지 못하며 일부 잔존 열화가 남는 한계가 있다. 실제로, 전체 데이터를 사용한 보상 결과에서도 열화가 심한 픽셀에서는 미세한 휘도 불균일이 관찰된다. 그러나 주목할 점은, 이러한 한계에도 불구하고 1/256의 저용량 데이터만을 이용한 SR 결과가 Ground Truth(GT, 전체 데이터 보상 결과) 대비 PSNR 54.87, SSIM 0.99라는 매우 높은 정량적 성능을 달성하였다는 점이다. 이는 제안하는 SR 기법이 보상 과정의 근본적인 한계와 독립적으로, 저용량 데이터로부터 전체 데이터의 결과를 매우 정확하게 예측하고 복원할 수 있음을 입증한다. 따라서 향후 데이터 카운팅 기반 열화 보상 모델의 정확도가 향상된다면, SR을 적용한 최종 결과물의 품질 또한 비례하여 개선될 것으로 기대된다.




Fig. 16. Top: visual comparison according to the number of accumulated images
 Middle: x16 super-resolution performance of each model under fixed-pattern ('logo') conditions [21]
 Bottom: performance comparison when multiple logos are overlapped at the same position

Table 6. Evaluation of sequential upscaling effects at 16x super-resolution by changing the order of individually trained x2 and x4 models ('Step' denotes the training order, where Step 1 starts from the lowest resolution.)

	Ablation						Ref			
	x2SU Step 4-3-2-1		x2SU Step 2-1-3-4		x4SU Step 2-1		x2SU Step 1-2-3-4		x4SU Step 1-2	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
BSD100	18.53	0.40	21.12	0.43	20.75	0.44	21.15	0.43	21.20	0.44
MANGA109	16.18	0.50	18.25	0.56	17.99	0.56	18.27	0.56	18.28	0.57
Urban100	15.59	0.35	18.21	0.42	17.78	0.42	18.22	0.41	18.25	0.42
DIV8k	23.79	0.65	26.71	0.69	26.42	0.69	26.68	0.68	26.78	0.69
DIV2k	19.05	0.50	22.00	0.55	21.58	0.56	22.03	0.55	22.08	0.56

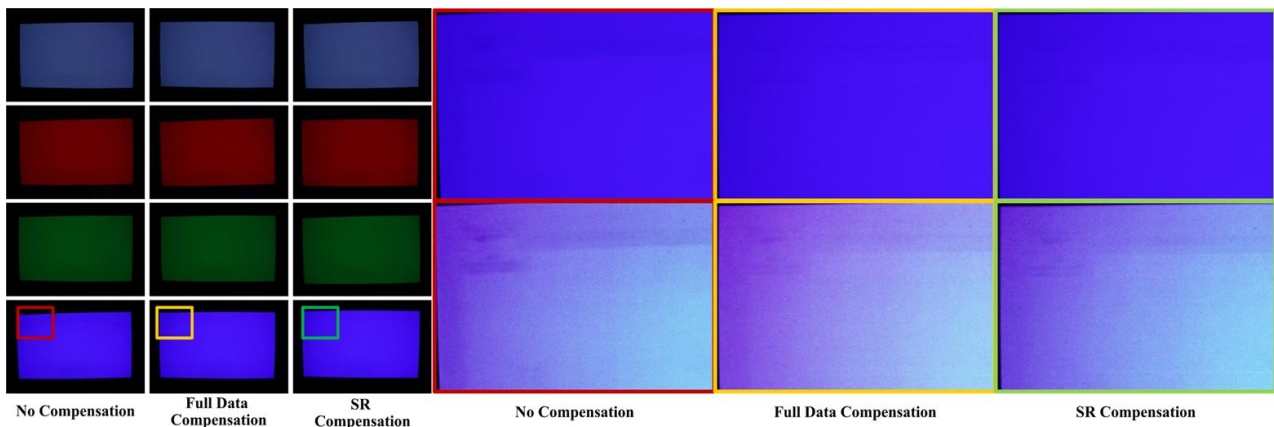


Fig. 17. Comparison of OLED compensation results after 6,500 hours of operation using full-data and 1/16-scale data accumulation (Blue box area: top—original, bottom—visually enhanced image.)

2.5 Ablation study

순차적 단계별 학습 전략의 유효성을 검증하기 위해, 개별적으로 학습된 x2, x4 모델들의 적용 순서를 의도적으로 변경하며 성능 변화를 분석했다. 표 6은 제안 모델의 앙상블 결과와, 적용 순서를 변경했을 때의 성능을 비교하여 보여준다. 실험 결과, 모든 모델이 동일하게 x2 또는 x4 배율로 학습되었음에도 불구하고, 학습된 순서와 다른 순서로 모델을 적용할 경우 성능 저하가 관찰되었다. 특히, 학습 순서를 완전히 역으로 적용했을 때 가장 큰 폭의 성능 저하가 나타났다.

IV. Conclusions

본 연구에서는 실제 구동 시나리오 기반의 HR-LR 데이터셋을 활용하여, 메모리 효율적인 OLED 열화 보상을 위한 초해상도(SR) 기술의 실질적인 효용성을 검증했다. 인위적인 열화 가정이 없는 데이터셋을 통해 SR 모델이 안정적인 복원 성능을 보임을 확인했으며, 특히 고배율 SR을 위해 제안한 '순차적 업스케일링(Sequential Up-scaling)' 기법의 우수성을 입증했다. 최종적으로, 제안 기법을 통해 x16 초해상도를 달성하여 메모리 사용량을 1/256으로 절감하였고, 6,500시간의 열화 가속 테스트 환경에서 PSNR 54.87, SSIM 0.99의 높은 예측 정확도를 기록하였다.

본 연구의 성과를 바탕으로 향후 다음과 같은 후속 연구를 진행하고자 한다. 첫째, 초해상도 성능의 최적화를 위해 실기기 구동 환경과 유사한 저해상도 데이터 생성 기법을 탐구할 예정이다. 신뢰도 높은 다운샘플링 모델의 확보는 전체 초해상도 프로세스의 정확도를 제고하는 데 핵심적인

기여를 할 것으로 기대된다. 둘째, OLED 패널 고유의 특성이 인 잔존 열화가 초해상도 성능 평가의 신뢰성에 미치는 영향을 심층적으로 분석하고자 한다. 이는 단순히 수치상의 고해상도 영상 복원을 넘어, 패널의 물리적 특성까지 통합적으로 고려한 예측 모델을 개발함으로써 초해상도 기술의 산업적 활용 가능성을 확대하는 데 기여할 것이다.

ACKNOWLEDGEMENT

This work was supported by the Institute of Information & Communications Technology Planning & Evaluation(IITP)-Innovative Human Resource Development for Local Intellectualization program grant funded by the Korea government (MSIT)(IITP-2026-RS-2022-00156360)

REFERENCES

- [1] Kensuke Umehara, Junko Ota, Naoki Ishimaru, Shunsuke Ohno, Kentaro Okamoto, Takanori Suzuki, and Takayuki Ishida. Performance evaluation of super-resolution methods using deep-learning and sparse-coding for improving the image quality of magnified images in chest radiographs. *Open Journal of Medical Imaging*, 7(03):100-111, 2017. <https://doi.org/10.4236/ojmi.2017.73010>
- [2] Yifan Wang, Federico Perazzi, Brian McWilliams, Alexander Sorkine-Hornung, Olga Sorkine-Hornung, and Christopher Schroers. A fully progressive approach to single-image super-resolution. In *Proceedings of the IEEE conference on*

- computer vision and pattern recognition workshops, pages 864–873, 2018. <https://doi.org/10.1109/CVPRW.2018.00122>
- [3] Xingtong Jiang and Chihao Xu. Data-counting model for empirical prediction of oled degradation. In Proc IDW, 2016. <https://doi.org/10.3390/app10228185>
- [4] Xingtong Jiang and Chihao Xu. 35-3: Invited paper: An electro-optical oled model for prediction and compensation of amoled aging artifacts. In SID Symposium Digest of Technical Papers, volume 49, pages 441–444. Wiley Online Library, 2018. <https://doi.org/10.1002/sdtp.12726>
- [5] Joon-Min Park. Display device and method of driving the same, August 31 2021. US Patent 11,107,404.
- [6] Hongyi Zhang, Moustapha Cisse, Yann N Dauphin, and David Lopez-Paz. mixup: Beyond empirical risk minimization. arXiv preprint arXiv:1710.09412, 2017.
- [7] Yong Guo, Jian Chen, Jingdong Wang, Qi Chen, Jiezhong Cao, Zeshuai Deng, Yanwu Xu, and Mingkui Tan. Closed-loop matters: Dual regression networks for single image super-resolution. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pages 5407–5416, 2020. <https://doi.org/10.1109/CVPR42600.2020.00545>
- [8] Rao Muhammad Umer, Gian Luca Foresti, and Christian Micheloni. Deep generative adversarial residual convolutional networks for real-world super-resolution. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, pages 438–439, 2020.
- [9] Xiangyu Chen, Xintao Wang, Jiantao Zhou, Yu Qiao, and Chao Dong. Activating more pixels in image super-resolution transformer. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pages 22367–22377, 2023. <https://doi.org/10.1109/CVPR52723.2023.02142>
- [10] <https://tvn.cjenm.com>. The tvn logo used in this paper is a trademark of tvn.
- [11] Zhen Li, Jinglei Yang, Zheng Liu, Xiaomin Yang, Gwanggil Jeon, and Wei Wu. Feedback network for image super-resolution. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pages 3867–3876, 2019. <https://doi.org/10.1109/CVPR.2019.00399>
- [12] Xintao Wang, Liangbin Xie, Chao Dong, and Ying Shan. Real-esrgan: Training real-world blind super-resolution with pure synthetic data. In Proceedings of the IEEE/CVF international conference on computer vision, pages 1905–1914, 2021. <https://doi.org/10.1109/ICCV48922.2021.00192>
- [13] Eirikur Agustsson and Radu Timofte. Ntire 2017 challenge on single image super-resolution: Dataset and study. In The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, July 2017. <https://doi.org/10.1109/CVPRW.2017.150>
- [14] Kiyoharu Aizawa, Azuma Fujimoto, Atsushi Otsubo, Toru Ogawa, Yusuke Matsui, Koki Tsubota, and Hikaru Ikuta. Building a manga dataset “manga109” with annotations for multimedia applications. IEEE MultiMedia, 27(2):8–18, 2020. <https://doi.org/10.1109/MMUL.2020.2984531>
- [15] Final 5. set5 dataset. <https://universe.roboflow.com/final-5/set5-i8fmk> apr 2023. URL <https://universe.roboflow.com/final-5/set5-i8fmk>. visited on 2023-08-30.
- [16] Shuhang Gu, Andreas Lugmayr, Martin Danelljan, Manuel Fritsche, Julien Lamour, and Radu Timofte. Div8k: Diverse 8k resolution image dataset. In 2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW), pages 3512–3516. IEEE, 2019. <https://doi.org/10.1109/ICCVW.2019.00434>
- [17] Muhammad Haris, Gian Luca Foresti, and Christian Micheloni. Deep back-project networks for single image super-resolution. IEEE Transactions on Pattern Analysis and Machine Intelligence, 43(12):4323–4337, 2020. <https://doi.org/10.1109/TPAMI.2020.3013203>
- [18] Jia-Bin Huang, Abhishek Singh, and Narendra Ahuja. Single image super-resolution from transformed self-exemplars. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 5197–5206, 2015. <https://doi.org/10.1109/CVPR.2015.7299156>
- [19] Zhi-Song Liu, Li-Wen Wang, Chu-Tak Li, Wan-Chi Siu, and Yui-Lam Chan. Image super-resolution via attention based back projection networks. In 2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW), pages 3517–3525. IEEE, 2019. <https://doi.org/10.1109/ICCVW.2019.00435>
- [20] Yulun Zhang, Kunpeng Li, Kai Li, Lichen Wang, Bineng Zhong, and Yun Fu. Image super-resolution using very deep residual channel attention networks. In Proceedings of the European conference on computer vision (ECCV), pages 286–301, 2018. https://doi.org/10.1007/978-3-030-01267-8_18
- [21] <https://www.kbs.co.kr>. The korea broadcasting system (kbs) logo used in this paper is a trademark of kbs.

Authors



Joon-Min Park received the B.S. and M.S. degrees in Applied Physics from Hanyang University, Korea, in 2006 and 2008, respectively. Mr. Park joined LG Display, Korea, as a researcher in 2009. Since 2022,

he has been with the Computer Vision Laboratory in the Department of Software at Soongsil University, Korea, where he is currently pursuing the Ph.D. degree. His research interests include computer vision, image processing, and display degradation compensation.



Seon-Yoo Kim received the B.S. degree in Computer science from Sungkyul University, Korea, in 2023, and the M.S. degree in Department of Software from Soongsil University, Korea, in 2025.

Ms. Kim is currently with an AI-related company as a researcher. Her research interests include artificial intelligence, specifically focusing on computer vision and anomaly detection.



Gye-Young Kim(Member, IEEE) received the B.S., M.S., and Ph.D. degrees in computer science and engineering from Soongsil University, Seoul, South Korea, in 1990, 1992, and 1996, respectively, with a focus on

computer vision. Prof. Kim worked with the Electronics and Telecommunications Research Institute (ETRI) and Korea Electric Power Corporation (KEPCO). He was a Visiting Professor with Indian Institute of Technology Bombay (IITB), in 2007, and a Visiting Scholar with the University of California (UCI), Irvine, from 2014 to 2015. He is currently a Professor with the School of Software, Soongsil University. His research interests include computer vision, machine learning, ultra-high speed camera recognition, and 3D vision.