

일반논문 (Regular Paper)

방송공학회논문지 제27권 제6호, 2022년 11월 (JBE Vol.27, No.6, November 2022)

<https://doi.org/10.5909/JBE.2022.27.6.906>

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

최근접 이웃 커널을 이용한 깊이 영상 완성 기술

정 태 현^{a)}, 우딘 쿠티^{a)}, 오 병 태^{a)‡}

Depth Map Completion using Nearest Neighbor Kernel

Taehyun Jeong^{a)}, Kutub Uddin^{a)}, and Byung Tae Oh^{a)‡}

요 약

본 논문에서는 희소 깊이 영상과 컬러 영상을 이용해 조밀한 깊이 영상을 추정하는 깊이 완성을 수행하기 위해 최근접 이웃 커널 기술을 사용하는 방식의 네트워크를 제안한다. 먼저 예측하고자 하는 깊이 영상을 대략적인 깊이 정보의 구조 정보를 포함하는 부분과 세밀한 깊이 정보를 가지는 상세 부분으로 분할하여 예측하는 방식을 제안한다. 이 과정에서 깊이 영상의 구조 및 상세 정보는 분류 기법과 회귀 기법을 활용하여 각각 추정하였으며, 특히 분류 과정에서 최근접 이웃 커널 정보를 활용하여 주변 정보를 통해 분류를 진행하는 방식을 제안하였다. 제안 방식은 기존의 희소 깊이 완성 방식과 비교하여 우수한 성능을 나타냈고, 시각적으로도 만족할만한 결과를 보이게 됨을 확인하였다.

Abstract

In this paper, we propose a new deep network architecture using nearest neighbor kernel for the estimation of dense depth map from its sparse map and corresponding color information. First, we propose to decompose the depth map signal into the structure and details for easier prediction. We then propose two separate subnetworks for prediction of both structure and details using classification and regression approaches, respectively. Moreover, the nearest neighboring kernel method has been newly proposed for accurate prediction of structure signal. As a result, the proposed method showed better results than other methods quantitatively and qualitatively.

Keyword : Depth completion, depth map, kernel estimation, deep learning, deep network

a) 한국항공대학교 항공전자정보공학부(Electornics and Information Engineering)

‡ Corresponding Author : 오병태(Byung Tae Oh)

E-mail: byungoh@kau.ac.kr

Tel: +82-300-0409

ORCID: <https://orcid.org/0000-0003-1437-2422>

※ This research was supported in part by the Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of ICT (NRF-2022R1A2C1005769), and by the GRRC program of Gyeonggi Province [2017-B02, Study on 3D Point Cloud Processing and Application Technology].

· Manuscript September 22, 2022; Revised October 19, 2022; Accepted October 19, 2022.

I. 서론

최근 영상 센싱 기술의 발전으로 영상을 표현하는 기존의 컬러 영상 데이터와 다른 형태의 데이터를 이용해 시각화 혹은 처리하는 방식이 활발하게 연구되고 있다. 그 중에서도 특히 ToF, LiDAR 등의 거리측정 센서로 얻을 수 있는 깊이 영상 (depth map)과 같은 3차원 공간정보를 가진 데이터에 대한 처리기술은 자율주행, 3차원 영상, VR 등 미래의 여러 분야에서 활발하게 사용될 것으로 전망된다.

깊이 영상은 하드웨어의 특성 및 한계로 인하여 일반적인 컬러 영상만큼 높은 해상도의 데이터를 획득하기 어렵고, 어떤 픽셀에서 유효한 데이터가 관측될지 특정할 수 없다는 특징이 있다. 이러한 특성을 가진 희소 깊이 영상 (sparse depth map)의 관측되지 않은 비유효 픽셀들을 추정하여 컬러영상과 같은 해상도의 조밀한 깊이 영상 (dense depth map)을 획득하는 과업을 깊이 완성 (depth completion)이라고 한다. 일반적으로 깊이 완성을 수행하기 위한 딥러닝 네트워크는 희소 깊이 영상 뿐만 아니라 텍스처 정보를 학습하기 위해서 컬러 영상 또한 입력으로 사용한다. 딥러닝 네트워크는 주어진 희소 깊이 영상의 정보를 바탕으로 컬러 정보를 레퍼런스로 삼아 다양한 방식을 이용하여 조밀한 깊이 영상을 완성하는 구조를 가지고 있다.

제안 방식에서는 기존 일반적으로 적용되는 방식에서 벗어나, 깊이 영상을 구조와 상세 정보로 분리하고, 각각의 정보를 분리하여 예측하는 네트워크를 제안한다. 이때, 구조 정보는 분류기법 기반의 예측, 상세 정보는 회귀 기법 기반의 예측을 각각 적용하며, 특히 구조 정보의 경우 주변 픽셀의 정보를 활용하여 예측하는 기법을 제안한다. 이러한 제안 기법은 기존의 복잡한 구조보다 간단하면서도 비견될만한 성능을 보여주고 있다.

본 논문은 다음과 같이 구성된다. 먼저 2장에서 깊이 영상 완성의 기존 기술에 대한 대략적인 소개 및 기술적인 분류를 소개한다. 3장에서는 기존 기술을 바탕으로 새롭게 제안된 기술에 대하여 소개하며, 4장에서 제안 기술에 대한 검증에 대한 실험결과 및 분석을 진행한다. 마지막으로 5장에서 제안 연구에 대한 결론을 제시한다.

II. 관련 기술

딥러닝 기반의 깊이 완성은 Sparsity-Invariant CNN^[1] 방식이 제안되면서 활발히 연구가 시작되었다. 해당 모델은 최초로 깊이 완성 문제를 딥러닝 네트워크를 통해 해결하고자 한 논문으로, 희소 영상의 특성을 잘 학습하기 위해 희소 영상에 대응하는 이진 마스크를 은닉층에서 맥스 풀링을 통해 전달하며, 특징을 추출 하는 모델이다. 또한 [2-4]와 같이 CNN 기반의 모델들이 제시 되었으나, 희소 깊이 영상만을 입력으로 사용해 네트워크를 학습시키는 단일 모델 방식은 희소 깊이영상의 불연속성 문제와 텍스처를 제대로 학습시키지 못하는 한계가 존재한다. 이후 제안된 깊이 완성 모델들은 ResNet^[5]을 기반으로한 UNet^[6] 구조를 바탕으로 범선 백터^[7], RGB 카메라^[8,9], 의미론적 영상^[10,11] 등의 다양한 부가정보를 추가로 활용한 다중 모델 방식으로 설계하여 성능을 향상시켰다.

1. 컬러영상을 활용한 깊이 완성

최근 가장 활발히 연구되고 있는 방식은 깊이 영상만을 이용하는 것이 아닌 컬러 영상 또한 추가로 활용하여 깊이 완성을 수행하는 방식이다. 깊이 완성 모델은 네트워크 구조에 따라 이분(Two-Branch) 방식과 공간 전파(Spatial Propagation) 방식으로 분류할 수 있다^[12].

이분 방식은 컬러 영상과 희소 깊이 영상을 각각 다른 구조를 가지는 네트워크를 통해 특징을 추출하여 두 특징을 융합시키는 방식에 초점을 둔 방식이다. Guide-Net^[13]은 컬러 영상으로 만든 특징영상을 이용해 동적 필터를 생성하고, 희소 깊이 영상 네트워크에 적용하는 방식이다. PE-Net^[14] 또한 컬러 영상과 희소 깊이 영상에 대해 다른 네트워크를 사용해 각각 완성 깊이영상과 신뢰도 영상을 추정하고, 두 영상을 신뢰도 영상 기반으로 가중 합을 함으로써 최종 깊이영상을 획득하게 된다. RigNet^[15]은 컬러 영상에 중점을 두어 반복적인 UNet구조를 통해 정제된 컬러 특징영상을 여러 융합 방식을 사용해 희소 깊이 영상의 특징과 결합하여 최종 깊이 영상을 추정한다.

공간전파 방식은 희소 깊이영상의 픽셀값을 전파 시키는 알고리즘으로 깊이 완성을 수행하는 방식이다. [3]은 이러

한 SPN 방식을 최초로 제안한 모델로서 깊이 영상의 픽셀 간 유사도를 정의하는 유사도 행렬을 추정하여 픽셀값이 각 방향으로 전파되도록 영상에 적용한다. CSPN^[16]의 경우 유사도 행렬에 대각선 방향을 추가하고 커널 형태로 정의하여 반복적인 연산을 통해 희소 깊이영상 값이 해당 픽셀 주변으로 전파되도록 설계되었고, CSPN++^[17]는 CSPN에 반복연산 횟수, 커널 사이즈를 적응적으로 추정하도록 설계되어 성능을 더욱 높였다. DSPN^[18]은 커널에 대한 오프셋을 추정하여 변형 가능(deformable) 커널 형태로 적용시켰고, NLSPN^[19]은 이웃 픽셀이 아니지만 관계성이 더 큰 먼 픽셀에 집중한 형태의 커널을 제시하였다. DySPN^[20]은 커널 연산의 각 반복 과정마다 어텐션 메커니즘을 적용하여 적응적으로 픽셀 전파가 되도록 설계된 네트워크이다.

2. 잔차 회귀 방식의 깊이 완성

영상의 잔차를 회귀하는 방식은 여러 과업^[5,21-22]을 통해 효율성이 입증되었다. 이는 깊이 완성에서도 적용될 수 있다. FCFR-Net^[23]은 입력 희소 영상을 사전에 다른 모델에 의해 전처리된 가완성 깊이영상 (pseudo dense depth)을 입력 받고, 특징영상들의 채널 셔플과 에너지 기반의 융합을 통해 잔차를 추정하는 방식으로 동작한다. DenseLIDAR^[24]의 경우, 간단한 커널 기반의 모폴로지 방식을 통해 가완성 깊이 영상을 만들고 이에 대한 잔차를 추정한다. UARLNet^[25]는 가완성 깊이 영상을 네트워크를 통해 만들고 불확실성 손실 함수를 이용해 부정확한 영역에 대한 잔

차를 더욱 잘 회귀하도록 설계되었다. Plane-Residual Net^[26]은 깊이 영상을 깊이 값을 기준으로 여러 개의 평면으로 분할하여 평면 영상과 잔차 영상으로 표현하고, 이를 예측하도록 네트워크를 학습시키는 방식을 제안한다. 각 픽셀마다 어떤 평면에 속하는지는 분류 손실함수를 적용하여 찾고, 잔차는 회귀 손실함수를 적용하여 찾는다. 이는 대략적인 깊이 영상의 구조를 평면을 통해 찾고, 디테일은 잔차를 통해 찾는 방식이다.

III. 제안 기법

1. 전체적인 네트워크 구조

본 논문에서는 찾고자 하는 깊이 영상의 정보를 구조 정보와 상세 정보로 분리하여 예측하는 방식을 제안한다. 이를 위하여 각각의 컬러 및 깊이 영상에 대하여 상호 보완적으로 특징영상을 추출하고, 이를 바탕으로 그림 2와 같이 인코더-디코더 구조를 활용하여 구조 정보와 상세 정보를 예측하는 네트워크 구조를 제안한다. 전체 네트워크는 1개의 공통 인코더와 2개의 디코더를 포함하고 있다. 먼저 인코더 파트에서는 각각의 컬러 및 깊이 영상에서 컨볼루션 네트워크를 활용하여 특징영상을 생성하고, 이들을 연결하여 반복적으로 차원을 줄여나가는 보편적인 형태를 가지고 있다. 디코더 파트는 2개의 서브 네트워크로 구성되어 있으며, 이중 위쪽 서브 네트워크가 구조 정보를 예측하는 부분,




그림 1. 깊이 영상 완성 과업 예시
Fig. 1. Example of depth image completion task

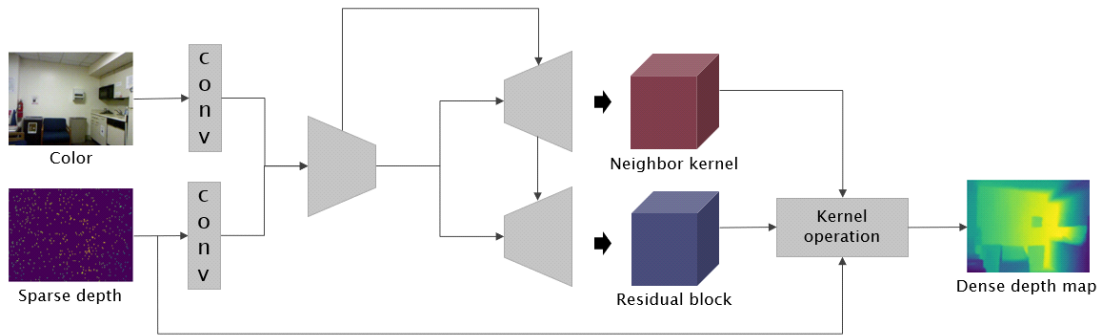


그림 2. 전체 네트워크 구조
 Fig. 2. Overall architecture of the proposed network

그리고 아래쪽 서브 네트워크가 상세 정보를 예측하는 부분을 각각 담당하도록 설계되었다. 이때, 깊이 영상의 구조 및 상세 정보에 대한 분리 예측, 그리고 분류 기법과 회귀 기법을 병행하여 사용하는 방식은 **Plane-Residual net**^[26]과 유사하지만, 구조 및 상세 정보를 찾아내는 과정에서 제안 방식과 큰 차이가 있다. 이에 대한 상세한 설명은 아래 세부절에서 설명한다.

2. 최근접 이웃 커널 기반 구조 정보 예측

구조 정보를 예측하기 위하여 제안 방식에서는 최근접 이웃 커널 방식을 제안한다. 최근접 이웃 커널이란 현재 예측하고자 하는 위치의 구조 정보는 반드시 주변 $K \times K$

블록 내의 1개 이상의 구조 정보와 일치하다는 가정이다. 일반적으로 깊이 영상의 경우 평탄한 영역이 많고, 급격한 영상 변화가 작게 되기 때문에, 구조 정보가 적어도 1가지 이상의 방향에서 연결되어 있다는 가정은 일반적으로 성립한다. 이를 바탕으로 그림 3의 위쪽 네트워크에서 최근접 이웃 커널 예측을 예측하여 모든 픽셀 위치의 구조 정보간의 유사도를 예측하게 된다. 이는 기존 **Plane-Residual Net** 방식에서 정해진 구간으로 깊이 영상의 구조 정보를 고정하고, 이를 예측하는 것과는 크게 상이하며, 실제 최근접 이웃 방식을 사용했을 때의 예측 정확도를 기존 방식과 비교해보면 그림 4와 같이 제안방식에서 찾아야 할 잔차 신호의 크기가 크게 줄어들어 있음을 확인할 수 있다.

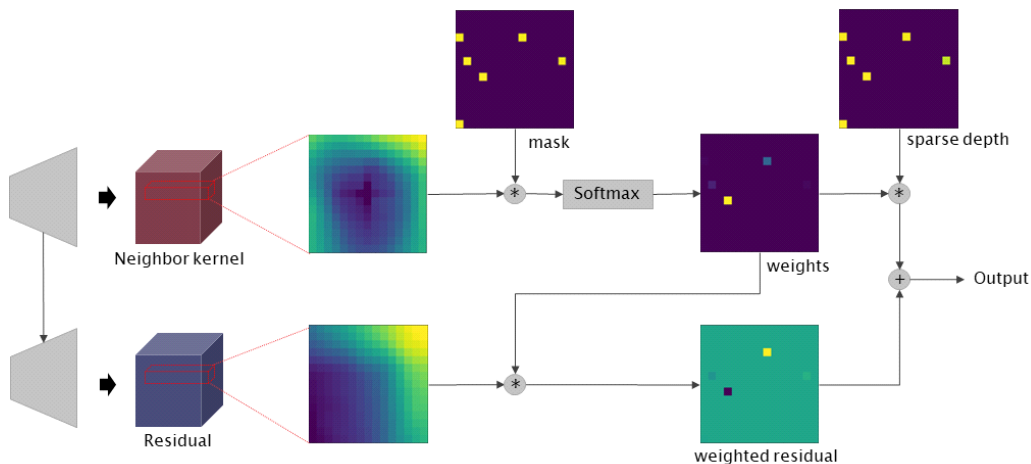


그림 3. 최근접 이웃 커널을 활용한 구조 및 상세 정보 예측 네트워크
 Fig. 3. Depth structure and details estimation network using nearest neighbor kernel




그림 4. 추정해야 할 잔차 영상 비교: Ground-Truth (왼쪽), Plane-Residual Net [26] (중앙), 제안 방식 (오른쪽)
 Fig. 4. Comparison of residual image: Ground-Truth (left), Plane-Residual Net [26] (center), proposed method (right)

3. 상세 정보 예측

그림 3의 아래쪽 부분에서 보여주고 있는 바와 같이 상세 정보를 예측하는 부분도 구조적으로는 앞서 설명한 최근접 이웃 커널의 디코더와 동일한 형태를 가진다. 이때, 구조 정보의 예측 과정에서 각각의 공간적인 위치의 구조 정보가 반영되는 확률을 계산한 반면, 상세 정보 예측 네트워크에서는 각각의 구조 정보가 반영되었을 때 발생하게 되는 잔여분의 상세 정보를 예측하게 된다. 상세 정보 예측 과정에서 앞서 예측된 구조 정보가 도움이 되기 때문에, 각 단계에서의 특징영상이 전파되는 식으로 구성되었다. 최종적으로 구조 정보와 상세 정보의 출력값의 차원은 서로 일치하게 된다.

4. 네트워크 구조 및 학습

그림 3을 참조하면, 최근접 이웃 커널은 인근의 유효 픽셀에 의해 마스킹되며, 소프트맥스 함수를 취해 각각의 유효 픽셀들에 대한 가중치를 추정한다. 마스킹은 상세정보 예측에도 적용되어, 최종적으로 커널 영역 내부의 유효픽셀들과 잔차의 가중합으로 완성 깊이영상의 픽셀값을 추정하게 된다.

이러한 구조정보와 상세정보의 학습을 위하여 각각 서브

네트워크의 결과에 손실 함수를 적용하는 방식으로 학습을 진행하였다. 최종적으로 사용한 손실 함수 L_T 는 아래 수식 (1)과 같이 구해진다.

$$L_T = L_S + \lambda L_D \quad (1)$$

여기서 L_S 와 L_D 는 각각 구조 정보를 위한 Cross-Entropy 손실 함수와 상세 정보를 위한 L1 손실함수를 의미하며, 실험에서 $\lambda = 1$ 으로 세팅되었다.

구조 정보와 상세 정보 예측을 위한 커널의 크기 K 는 실험에서 모두 11로 고정하였으며, 인코더-디코더 구조에서는 각 계층별 전파를 위해 UNet^[6] 구조를 사용하였다.

IV. 실험 결과

본 논문의 깊이 완성 네트워크를 평가하기 위해 NYUv2 데이터셋을 사용하였다^[27]. NYUv2는 마이크로소프트의 키넥트를 통해 얻은 여러 실내영상의 RGB-D 데이터셋이다. NYUv2는 48k개의 훈련데이터 셋과 654개의 테스트 데이터셋으로 구성되고, 컬러영상은 640x480의 사이즈를 가지나 깊이 영상과 해상도를 맞추기 위해 다운 샘플링을 적용한 후 중심 크롭을 통해 304x228 사이즈로 변환한다.

NYUv2 데이터셋의 깊이 영상의 경우 정답 영상 전체 픽셀에서 500개에 해당하는 비율로 랜덤 샘플링하여 최소 깊이 영상을 만든다.

제안방식의 실험은 최적화를 위해 Adam 옵티마이저를 사용하였고, 초기 학습률, β_1, β_2 는 각각 10^{-3} , 0.9, 0.999로 설정했다. 또한 오버피팅을 최소화 하기 위해 가중치 감쇠 (weight decay)를 사용했고, 규제 파라미터를 10^{-6} 으로 설정했다. 전체 훈련데이터 셋에 대하여 총 40에포크를 학습 하였고, 3에포크동안 평가 성능이 개선되지 않으면 학습률을 10^{-1} 만큼 감소시키는 스케줄러로 학습을 진행했다.

일반적으로 깊이 영상을 평가할 때 Root Mean Square Error (RMSE)와 Mean Absolute Relative Error (REL)를 사용한다. 각각의 수식은 아래와 같다.

$$RMSE(m) : \sqrt{\frac{1}{v} \sum_i (d_i^* - d_i)^2} \quad (2)$$

$$REL(m) : \frac{1}{v} \sum_i \left| \frac{d_i - d_i^*}{d_i^*} \right| \quad (3)$$

이때, d 는 네트워크가 예측한 값, d^* 는 정답 값(Ground-Truth), v 는 전체 픽셀의 개수를 의미한다.

표 1은 여러 깊이 완성 모델들과의 성능을 비교하기 위해

도시한 결과이다. 여러 SOTA 모델들과 비교하여 우수한 성능을 보였고, 본 논문과 유사하게 잔차의 범위를 줄여 픽셀값을 추정하는 Plane-Residual Net 대비 약 4%의 성능을 향상시켰다.

표 1. 다양한 깊이 완성 방식 성능 비교

Table 1. Quantitative comparisons with various methods

Model	RMSE(m)	REL(m)
NConv [8]	0.129	0.018
CSPN [16]	0.117	0.016
FCFR-Net [23]	0.106	0.015
Plane-Residual Net [26]	0.104	0.014
Guide-Net [7]	0.101	0.015
Ours	0.100	0.013

그림 5에서는 주관적 성능평가를 위해 제안 방식과 기존 방식들의 결과 영상을 비교하였다. 아래 결과 영상에서와 같이 제안 방식으로 추정된 깊이 영상이 기존 방식과 비교하여 보다 선명하고 뚜렷한 형태를 가지는 깊이 영상을 만들었음을 확인할 수 있다. 특히 영상의 엣지 부근에서 Plane-Residual Net 모델은 잔차의 추정범위가 넓기 때문에 왜곡이 많이 발생하지만, 제안 방식에서는 이러한 현상이 매우 감소하는 것을 확인 할 수 있다. 이러한 점은 깊이 영

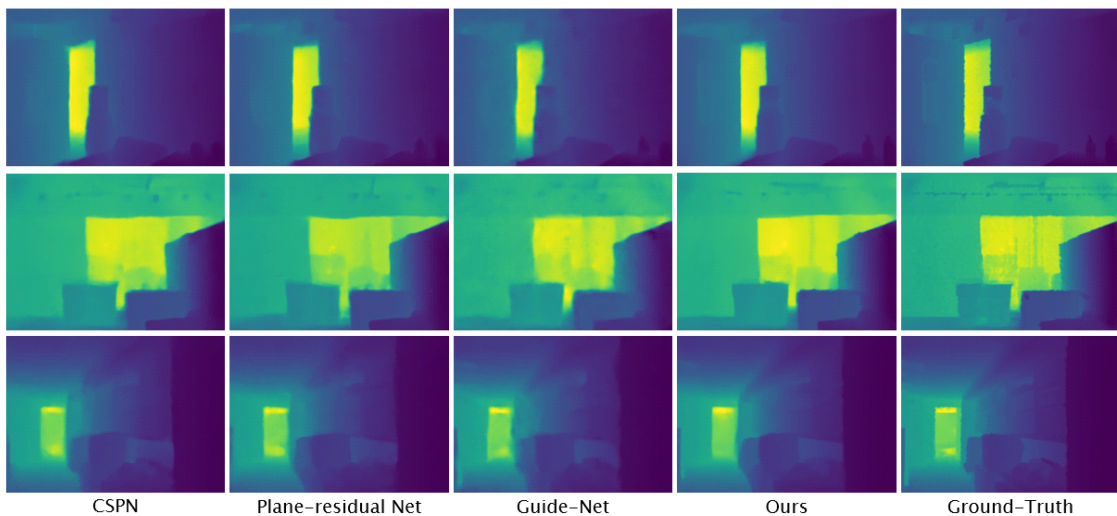


그림 5. 다양한 깊이 완성 기술의 시각적 비교

Fig. 5. Visual comparisons of various depth completion methods

상의 구조 정보를 명시적으로 복원하려는 네트워크 구조에서 발생한 것으로 추정된다.

V. 결론

본 논문은 깊이 완성을 위해 최근접 이웃 커널을 추정하여 입력 깊이 영상에 적용하는 방식을 제안하였다. 보다 정확한 깊이 값의 예측을 위해 깊이 영상을 구조 정보와 상세 정보로 나누고, 각각 분류와 회귀 문제로 다루는 방식을 제안하였으며, 회귀 과정에서 추정할 잔차의 범위를 줄이기 위해 인근 값에 잔차를 더하고 해당 픽셀값에 근접한 값을 가져오는 커널을 추정하는 방식을 새롭게 제안하였다. 결과적으로 제안 모델의 기존 방식과 비교하여 우수한 성능을 나타냄을 확인할 수 있다.

참고 문헌 (References)

- [1] Uhrig, Jonas, et al. "Sparsity invariant cnns." 2017 international conference on 3D Vision (3DV). IEEE, 2017.
doi: <https://doi.org/10.1109/3DV.2017.00012>
- [2] Chodosh, Nathaniel, Chaoyang Wang, and Simon Lucey. "Deep convolutional compressed sensing for lidar depth completion." Asian Conference on Computer Vision. Springer, Cham, 2018.
doi: https://doi.org/10.1007/978-3-030-20887-5_31
- [3] Liu, Sifei, et al. "Learning affinity via spatial propagation networks." Advances in Neural Information Processing Systems 30 (2017).
doi: <https://doi.org/10.48550/arXiv.1710.01020>
- [4] Ma, Fangchang, Guilherme Venturelli Cavalheiro, and Sertac Karaman. "Self-supervised sparse-to-dense: Self-supervised depth completion from lidar and monocular camera." 2019 International Conference on Robotics and Automation (ICRA). IEEE, 2019.
doi: <https://doi.org/10.1109/ICRA.2019.8793637>
- [5] He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
doi: <https://doi.org/10.1109/CVPR.2016.90>
- [6] Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation." International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015.
doi: <https://doi.org/10.48550/arXiv.1505.04597>
- [7] Qiu, Jiexiong, et al. "Deeplidar: Deep surface normal guided depth prediction for outdoor scene from sparse lidar data and single color image." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019.
doi: <https://doi.org/10.48550/arXiv.1812.00488>
- [8] Eldesokey, Abdelrahman, Michael Felsberg, and Fahad Shahbaz Khan. "Confidence propagation through cnns for guided sparse depth regression." IEEE transactions on pattern analysis and machine intelligence 42.10 (2019): 2423-2436.
doi: <https://doi.org/10.1109/TPAMI.2019.2929170>
- [9] Huang, Zixuan, et al. "Hms-net: Hierarchical multi-scale sparsity-invariant network for sparse depth completion." IEEE Transactions on Image Processing 29 (2019): 3429-3441.
doi: <https://doi.org/10.48550/arXiv.1808.08685>
- [10] Zhang, Chongzhen, et al. "Multitask gans for semantic segmentation and depth completion with cycle consistency." IEEE Transactions on Neural Networks and Learning Systems 32.12 (2021): 5404-5415.
doi: <https://doi.org/10.1109/TNNLS.2021.3072883>
- [11] Nazir, Danish, et al. "SemAttNet: Towards Attention-based Semantic Aware Guided Depth Completion." arXiv preprint arXiv:2204.13635 (2022).
doi: <https://doi.org/10.1109/ACCESS.2022.3214316>
- [12] Khan, Muhammad Ahmed Ullah, et al. "A Comprehensive Survey of Depth Completion Approaches." (2022).
doi: <https://doi.org/10.20944/preprints202205.0343.v1>
- [13] Tang, Jie, et al. "Learning guided convolutional network for depth completion." IEEE Transactions on Image Processing 30 (2020): 1116-1129.
doi: <https://doi.org/10.1109/TIP.2020.3040528>
- [14] Hu, Mu, et al. "Penet: Towards precise and efficient image guided depth completion." 2021 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021.
doi: <https://doi.org/10.48550/arXiv.2103.00783>
- [15] Yan, Zhiqiang, et al. "RigNet: Repetitive image guided network for depth completion." arXiv preprint arXiv:2107.13802(2021).
- [16] Cheng, Xinjing, Peng Wang, and Ruigang Yang. "Learning depth with convolutional spatial propagation network." IEEE transactions on pattern analysis and machine intelligence 42.10 (2019): 2361-2379.
doi: <https://doi.org/10.48550/arXiv.1810.02695>
- [17] Cheng, Xinjing, et al. "Cspn++: Learning context and resource aware convolutional spatial propagation networks for depth completion." Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 34. No. 07. 2020.
doi: <https://doi.org/10.48550/arXiv.1911.05377>
- [18] Xu, Zheyuan, Hongche Yin, and Jian Yao. "Deformable spatial propagation networks for depth completion." 2020 IEEE International Conference on Image Processing (ICIP). IEEE, 2020.
doi: <https://doi.org/10.48550/arXiv.2007.04251>
- [19] Park, Jinsun, et al. "Non-local spatial propagation network for depth completion." European Conference on Computer Vision. Springer, Cham, 2020.
doi: https://doi.org/10.1007/978-3-030-58601-0_8
- [20] Lin, Yuankai, et al. "Dynamic spatial propagation network for depth completion." arXiv preprint arXiv:2202.09769(2022).
doi: <https://doi.org/10.48550/arXiv.2202.09769>

- [21] Zhang, Kai, et al. "Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising."IEEE transactions on image processing26.7 (2017): 3142-3155.
doi: <https://doi.org/10.1109/TIP.2017.2662206>
- [22] Kim, Jiwon, Jung Kwon Lee, and Kyoung Mu Lee. "Accurate image super-resolution using very deep convolutional networks."Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
doi: <https://doi.org/10.48550/arXiv.1511.04587>
- [23] Liu, Lina, et al. "Fcfr-net: Feature fusion based coarse-to-fine residual learning for depth completion."Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 35. No. 3. 2021.
doi: <https://doi.org/10.1609/aaai.v35i3.16311>
- [24] Gu, Jiaqi, et al. "Denselidar: A real-time pseudo dense depth guided depth completion network."IEEE Robotics and Automation Letters6.2 (2021): 1808-1815.
doi: <https://doi.org/10.1109/LRA.2021.3060396>
- [25] Zhu, Yufan, et al. "Robust depth completion with uncertainty-driven loss functions."Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 36. No. 3. 2022.
doi: <https://doi.org/10.1609/aaai.v36i3.20275>
- [26] Lee, Byeong-Uk, Kyunghyun Lee, and In So Kweon. "Depth completion using plane-residual representation."Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021.
doi: <https://doi.org/10.48550/arXiv.2104.07350>
- [27] Silberman, Nathan, et al. "Indoor segmentation and support inference from rgb-d images."European conference on computer vision. Springer, Berlin, Heidelberg, 2012.
doi: https://doi.org/10.1007/978-3-642-33715-4_54

저 자 소 개



정 태 현

- 2021년 2월 : 한국항공대학교 항공전자정보공학부 (학사)
- 2021년 3월 ~ 현재 : 한국항공대학교 항공전자정보공학부 (석사과정)
- ORCID : <http://orcid.org/0000-0002-5793-2955>
- 주관심분야 : 영상처리, 영상압축



우 딴 쿠틀

- 2017년 7월 : University of Chittagong (학사)
- 2020년 8월 : 한국항공대학교 항공전자정보공학부 (석사)
- 2020년 9월 ~ 현재 : 한국항공대학교 항공전자정보공학부 (박사과정)
- ORCID : <http://orcid.org/0000-0003-4365-682X>
- 주관심분야 : 영상처리, 영상 포렌식



오 병 태

- 2003년 8월 : 연세대학교 전자공학과 (학사)
- 2007년 2월 : University of Southern California (석사)
- 2009년 8월 : University of Southern California (박사)
- 2009년 11월 ~ 2013년 2월 : 삼성 종합기술원 연구원
- 2013년 3월 ~ 현재 : 한국항공대학교 교수
- ORCID : <http://orcid.org/0000-0003-1437-2422>
- 주관심분야 : 영상처리, 영상 포렌식