

특집논문 (Special Paper)

방송공학회논문지 제26권 제3호, 2021년 5월 (JBE Vol. 26, No. 3, May 2021)

<https://doi.org/10.5909/JBE.2021.26.3.283>

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

# 라이다 깊이 맵과 이미지를 사용한 자기 조직화 지도 기반의 고밀도 깊이 맵 생성 방법

최한솔<sup>a)</sup>, 이종석<sup>a)</sup>, 심동규<sup>a)†</sup>

## Dense-Depth Map Estimation with LiDAR Depth Map and Optical Images based on Self-Organizing Map

Hansol Choi<sup>a)</sup>, Jongseok Lee<sup>a)</sup>, and Donggyu Sim<sup>a)†</sup>

### 요 약

본 논문은 자기 조직화 지도 기법을 기반으로 라이다 기반으로 생성된 깊이 맵과 컬러 이미지의 정보를 기반으로 고밀도 깊이 맵을 생성하는 방법을 제안한다. 제안하는 깊이 맵 업샘플링 방법은 라이다에서 취득되지 않은 공간에 대한 초기 깊이 예측 단계와 초기 깊이 필터링 단계로 구성된다. 초기 깊이 예측 단계에서는 두 장의 컬러 이미지에 대해 스테레오 매칭을 수행하여 초기 깊이 값을 예측한다. 깊이 맵 필터링 단계에서는 예측된 초기 깊이 값의 오차를 감소시키고자 예측 깊이 픽셀에 대하여 주변의 실측 깊이 값을 이용하여 자기 조직화 지도 기법을 수행한다. 자기 조직화 기법 수행 시 예측 깊이 픽셀과 실측 깊이 픽셀의 거리와, 각 픽셀에 대응되는 컬러 값의 차이에 따라 가중치를 결정한다. 본 논문에서는 성능 비교를 위하여 깊이 맵 업샘플링 방법으로 널리 사용되고 있는 양방향 필터 및 k-최근접 이웃 알고리즘과 비교를 진행하였다. 제안하는 방법은 양방향 필터 방법 및 k-최근접 이웃 알고리즘 대비 MAE 관점에서 각각 약 6.4%, 8.6%이 감소하였고 RMSE 관점에서 각각 약 10.8%, 14.3%이 감소하였다.

### Abstract

This paper proposes a method for generating dense depth map using information of color images and depth map generated based on lidar based on self-organizing map. The proposed depth map upsampling method consists of an initial depth prediction step for an area that has not been acquired from LiDAR and an initial depth filtering step. In the initial depth prediction step, stereo matching is performed on two color images to predict an initial depth value. In the depth map filtering step, in order to reduce the error of the predicted initial depth value, a self-organizing map technique is performed on the predicted depth pixel by using the measured depth pixel around the predicted depth pixel. In the process of self-organization map, a weight is determined according to a difference between a distance between a predicted depth pixel and an measured depth pixel and a color value corresponding to each pixel. In this paper, we compared the proposed method with the bilateral filter and k-nearest neighbor widely used as a depth map upsampling method for performance comparison. Compared to the bilateral filter and the k-nearest neighbor, the proposed method reduced by about 6.4% and 8.6% in terms of MAE, and about 10.8% and 14.3% in terms of RMSE.

Keyword : Depth map, LiDAR, Upsampling, Self-organizing map

Copyright © 2021 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

## 1. 서 론

최근 3차원 공간 정보 기반의 서비스가 자율 주행, 가상 엔터테인먼트, 농·산업 현장 원격 관리 등의 산업 전 분야로 급격히 확장되고 있다. 이와 같은 다양한 서비스에서 실감형 체험 응용 또는 상황 분석을 목적으로 도로 환경, 건축물, 실내외 환경 등의 3차원 공간 정보가 사용된다. 실제 공간의 3차원 공간 정보를 이용하는 응용에서 3차원 모델의 실감도를 높이고 공간 정보 분석 기반의 처리 과정의 정확도를 높이고자 공간 정보 조밀하고 정확하게 생성하는 것이 요구되어왔다. 3차원 공간 정보와 지정한 시점과의 거리 정보를 이미지 평면에 나타낸 것이 깊이 맵이고, 깊이 맵 도메인에서 높은 해상도의 공간 정보를 생성하기 위한 다양한 연구들이 진행되어왔다.

조밀한 깊이 맵을 생성하는 연구들이 크게 수동적 방법, 능동적 방법, 복합적 방법으로 진행되어 왔다. 수동적 방법은 광학 카메라에서 취득한 이미지로부터 깊이 정보를 예측하는 방법이다. 이미지는 깊이 정보가 손실되어 있기 때문에 단일 이미지 또는 다수개의 이미지를 이용하여 깊이 정보를 예측하는 방법이 연구되어왔다. 다수개의 이미지를 사용하는 연구에서 일반적으로 사용되는 대표적인 방법은 스테레오 정합과 움직임 기반 모양 추정 방법(Structure From Motion, SFM)이다. 스테레오 매칭 방법<sup>[1-3]</sup>은 양안 카메라로 취득한 영상의 시점 차를 이용하고 SFM 방법<sup>[4]</sup>은 여러 시점에서 촬영된 이미지의 카메라 위치를 추정하고 이를 이용하는 방법이다. 최근 단일 이미지만을 사용해

서 딥러닝 방법을 기반으로 깊이 예측을 수행하는 연구 또한 활발히 진행되고 있다. [17]은 단일 이미지와 이미지의 에지 맵을 함께 이용하여 깊이 예측의 성능을 향상시켰다. 또한 최근 딥러닝 기반의 이미지 초해상도화 연구가 다양한 분야에 적용되고 있고<sup>[18-19]</sup>, 깊이 맵 업샘플링 분야에 또한 적용되어 높은 성능을 보인다<sup>[20]</sup>. 영상 기반의 깊이 맵 예측 방법은 대중적으로 보급되고 있는 고해상도의 카메라를 사용하여 깊이 맵 예측을 수행할 수 있다는 장점이 있다. 능동적 방법은 라이더(Light Detection and Ranging, LiDAR), 레이더(Radio Detection And Ranging, RADAR), Time-of-Flight(ToF) 등의 깊이를 취득하는 센서를 이용하는 방법이다. 능동적 방법으로 취득한 3차원 모델은 취득된 깊이에 한하여 정밀도가 높다는 장점이 있지만, 광학카메라 대비 해상도가 현저히 낮다는 한계점이 있다. 따라서 이를 보완하기 위하여 깊이가 취득된 깊이를 기반으로 취득되지 않은 영역의 깊이를 예측하는 연구가 활발히 진행되고 있다. k-최근접 이웃(k-Nearest Neighbor, k-NN)<sup>[5]</sup>은 능동적으로 취득된 기하 정보에 샘플 간 거리만을 기준으로 수행될 수 있고, Moving Picture Experts Group-Immersive (MPEG-I)에서 진행되고 있는 기하 정보 기반의 포인트 클라우드 압축(Geometry-based Point Cloud Compression) 표준<sup>[6]</sup>에서 포인트의 속성 값을 예측하는 단계에서 사용된다. [7]은 양방향 필터(Bilateral Filter)<sup>[10]</sup>를 이용하여 깊이의 경계를 보존하면서 깊이맵을 업샘플링 하는 방법을 제안하였다. 깊이를 예측하고자 하는 픽셀을 중심으로 하는 윈도우 내 픽셀들을 군집화 하여 대상 픽셀과 깊이 차이가 큰 집합은 필터링에 사용하지 않음으로써 깊이 경계를 보존한다. 깊이 예측의 정확도를 더욱 향상시키고자 실측 깊이 정보와 컬러 이미지 등의 실측 비-깊이 정보를 함께 사용하는 복합적 방법이 활발히 연구되고 있다. [15]는 컬러 이미지의 화소 간 최대 변화도를 이용하여 깊이 맵 업샘플링을 수행하였다. [16]도 컬러 이미지를 이용하였고 깊이의 경계는 보존하면서 컬러 이미지의 질감이 깊이 맵에서 나타나는 문제를 개선하였다. [8-9]는 컬러 이미지의 의미적 분할(Semantic Segmentation)을 수행하여 얻은 객체의 경계 정보를 이용하여 객체의 경계면에서의 깊이 예측에 우수한 성능을 보였다. 컬러 이미지의 고해상도의 객체 경계 정보를 이용하여 객체의 경계에서 존재하는 라이더의 에러를 보완하였고, 라이더 깊이 정보만을

a) 광운대학교 컴퓨터공학과(Dept. of Computer Engineering, Kwangwoon University)

‡ Corresponding Author : 심동규(Donggyu Sim)

E-mail: dgsim@kw.ac.kr

Tel: +82-2-940-5470

ORCID: <http://orcid.org/0000-0002-2794-9932>

\* 이 기술은 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업(IITP-2021-2016-0-00288) 및 2021년도 광운대학교 우수연구자 지원 사업에 의한 연구결과로 개발한 기술입니다.

\*\* This research was supported by the MSIT(Ministry of Science and ICT), Korea, under the ITRC(Information Technology Research Center) support program(IITP-2021-2016-0-00288) supervised by the IITP(Institute for Information & communications Technology Planning & Evaluation) and the Excellent researcher support project of Kwangwoon University in 2021.

· Manuscript received April 26, 2021; Revised May 14, 2021; Accepted May 14, 2021.

이용하여 구별하기 어려운 깊이 차이가 적은 객체 또한 구분하여 업샘플링을 수행하였다. 이와 같이 컬러 이미지의 의미적인 정보를 업샘플링에 이용할 경우 객체의 경계에서의 정확한 깊이를 예측하는데 높은 성능을 보이지만 이미지의 의미적 분할 과정이 추가됨에 따라 복잡도가 높아진다.

앞서 소개한 의미적 분할 방법을 이용하는 등의 고성능의 방법들 경우에는 실제 응용에서 사용하기에는 계산 복잡도 문제가 여전히 남아있다. 따라서, 본 논문에서는 공간 정보 업샘플링 과정에서 일반적으로 사용되는 K-NN<sup>[5]</sup> 및 양방향 필터<sup>[10]</sup>와 제안하는 방법을 비교한다. K-NN<sup>[5]</sup> 및 양방향 필터<sup>[10]</sup> 기반의 깊이 맵 업샘플링 수행 과정은 예측 깊이 픽셀의 값을 예측하기 위하여 해당 픽셀의 주변의 실측 깊이 픽셀을 적어도 1개를 사용해야 된다. 이 과정에서 예측 깊이 픽셀과 주변의 실측 깊이 픽셀이 깊이의 연관성이 적은 경우 깊이 값 예측 오차가 크게 발생한다. 제안하는 방법은 깊이 예측 과정에서 도출한 스테레오 깊이 값을 함께 사용하여 주변에 연속성 있는 깊이 값이 없는 영역에 대해서도 기존 방법들 대비 깊이 예측 정확도를 향상시킨다. 또한 제안하는 방법은 실제 응용에서 시간적, 공간적으로 취득된 실측 깊이 값이 증가할 때마다 SOM을 수행하여 예측 오차를 점진적으로 감소시킨다. 따라서 기존 방법들과 같이 마지막 실측 깊이 데이터가 취득될 때까지 기다리지 않고 데이터가 취득될 때마다 업데이트를 수행하여 중간 예측 결과물을 사용할 수 있다는 장점이 있다. 본 논문에서는 라이다 취득 기반으로 생성된 희소한 깊이 맵과 동일 영역을 취득한 스테레오 컬러 이미지를 기반으로 이미지와 동일한 해상도를 갖는 조밀한 깊이 맵을 생성하는 방법을 제안한다. 제안하는 방법은 깊이 맵에서 실측 깊이 값이 존재하지 않는 픽셀들에 대하여 스테레오 매칭 기반 방법으로 초기 깊이 값을 예측한다. 깊이 값의 예측 오차를 감소시키기 위하여 주변의 실측 깊이 픽셀을 이용하여 자기 조직화 지도(Self-Organizing Map, SOM)<sup>[11]</sup> 기반의 깊이 값 필터링을 수행한다. 필터링 과정에서 예측 깊이 픽셀과 실측 깊이 픽셀의 픽셀 간 거리와 컬러 값의 차이를 기준으로 깊이 연관성을 판단하고, 예측 깊이 픽셀 값을 실측 깊이 픽셀 값의 방향으로 연관성 가중 업데이트를 수행한다. 제안하는 방법은 양방향 필터 방법 및 k-최근접 이웃 알고리즘 대비 MAE 성능 관점에서 각각 6.4%, 8.6%의 성능 향상이 있었고 RMSE 성능

관점에서 각각 약 10.8%, 14.3%의 성능 향상이 있었다.

본 논문의 구성은 다음과 같다. 2장에서 깊이 맵에 대한 설명과 기존의 조밀한 깊이 맵 생성 방법에 대하여 설명한다. 3장에서 제안하는 조밀한 깊이 맵 생성 방법에 대하여 설명한다. 4장에서 기존 방법과 제안하는 방법의 성능을 비교하고, 5장에서 결론을 맺는다.

## II. 기존의 조밀한 깊이 맵 생성 방법

### 1. 라이다 취득 기반의 깊이 맵

라이다는 레이저로부터 빛 펄스를 방출한 뒤 반사되어 돌아오는데 걸리는 시간을 기반으로 거리 정보를 취득하는 센서이다. 라이다는 취득한 포인트의 기하 정보를 구면 좌표계 상에서  $P(R, \omega, \alpha)$ 로 나타낸다. 포인트까지의 거리  $R$ 은 빛 펄스가 반사되어 돌아온 시간을 이용하여 유도된다. 수직 각도  $\omega$ 는 라이다에 수직 방향으로 배열된 레이저마다 고정 값을 갖는다.  $\alpha$ 는 라이다가 수평 회전 시 펄스를 방출하는 시점의 수평 각도이다. 구면 좌표계에서 직교 좌표계  $P(X, Y, Z)$ 로 변환하고 이후 이미지 평면으로의 투영 과정을 수행하여 희소한 깊이 맵이 생성된다.

그림 1은 라이다에서 취득된 포인트 클라우드의 기하 정




그림 1. 라이다 취득 기하 정보를 카메라 이미지 평면으로 투영하여 이미지 평면 상의 좌표를 유도하는 방법

Fig. 1. The process of deriving coordinates on the image plane by projecting the LiDAR acquisition geometric information onto the camera image plane

보가 임의의 이미지 평면으로 투영되는 과정을 나타낸다. 라이다 포인트 데이터에 대응되는 카메라 이미지의 픽셀 위치를 알아내고자 카메라의 이미지 평면 좌표계로 투영시키고, 해당 픽셀 값을 포인트까지의 거리  $R$ 로 표현한다. 라이다 좌표계에서 카메라 이미지 평면 좌표계로의 변환은 수식 1을 통해 수행된다.

$$\begin{matrix} \mathbf{S} & \mathbf{I} & \mathbf{RT} \\ \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} S_x f & 0 & C_x \\ 0 & S_y f & C_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X_L \\ Y_L \\ Z_L \\ 1 \end{bmatrix} \end{matrix} \quad (1)$$

행렬  $S$ 는 정규화된 이미지 평면에서 이미지 평면으로의 투영 행렬, 행렬  $I$ 는 3차원 공간 정보를 정규화된 이미지 평면으로의 투영 행렬, 행렬  $RT$ 는 라이다와 카메라 사이의 외부 좌표계 캘리브레이션 행렬이다. 라이다에서 취득된 포인트의 3차원 상의 공간 정보 ( $X_L, Y_L, Z_L$ )는 행렬  $RT$ 와의 연산을 통해 카메라 좌표계 상의 포인트 ( $X_C, Y_C, Z_C$ )로 변환된다. 행렬  $RT$ 의  $r_{11}$ 부터  $r_{33}$ 까지는 회전이동을 위한 파라미터이고  $t_x, t_y, t_z$ 는 평행이동을 위한 파라미터이다. 포인트 ( $X_C, Y_C, Z_C$ )는 행렬  $I$ 와의 연산을 통해 정규화

된 이미지 평면의 좌표 ( $u, v$ )로 투영된다. 좌표 ( $u, v$ )는 행렬  $S$ 와의 연산을 통해 카메라 이미지 평면의 픽셀 ( $x, y$ )로 변환된다. 행렬  $S$ 의  $f$ 는 카메라의 초점거리이고,  $C_x$ 와  $C_y$ 는 이미지 평면의 중심 좌표이고,  $S_x$ 와  $S_y$ 는 픽셀 단위로 변환하기 위한 스케일링 파라미터이다.

그림 2는 동일한 공간에 대한 컬러 이미지, 라이다 데이터, 희소한 깊이 맵을 시각적으로 나타낸다. 그림 2의 (a)는 컬러 이미지, (b)는 라이다 취득 기하정보, (c)는 (b)를 (a)의 평면으로 투영하여 생성된 희소한 깊이 맵이다. 희소한 깊이 맵의 해상도는 이미지 해상도의 약 10% 정도로 매우 희소하고 그림 2의 (c) 깊이 맵에서 시각적으로 확인할 수 있다.

그림 3은 라이다에서 취득된 공간 정보 기반의 희소한 깊이 맵의 지역적 특성을 나타낸다. 그림 3의 a와 같이 깊이의 불연속이 없는 물체의 경우, 라이다 픽셀들의 값이 모든 방향으로 점진적으로 변화한다. 따라서 픽셀 간 연결강도는 픽셀 간 거리에 반비례한다고 가정한다. 도로, 건물 외벽 등의 평탄한 면이 이의 경우에 해당된다. 반면 (b), (c)와 같이 객체의 경계 부분의 경우 깊이 값에 불연속이 생길 수 있다. 특히 (c)의 경우와 같이, 빠르게 움직이는 물체에 대하여 깊이 값의 에러가 크게 발생한다.




그림 2. (a) 라이다와 동일한 공간을 취득한 컬러 이미지, (b) 라이다 취득 포인트 클라우드, (c) 희소한 깊이 맵  
Fig. 2. (a) Color image that acquires the same space as the LiDAR, (b) Lidar acquisition point cloud, (c) Sparse depth map



그림 3. 라이다 깊이맵의 지역적 특성  
Fig. 3. Regional characteristics of the lidar depth map

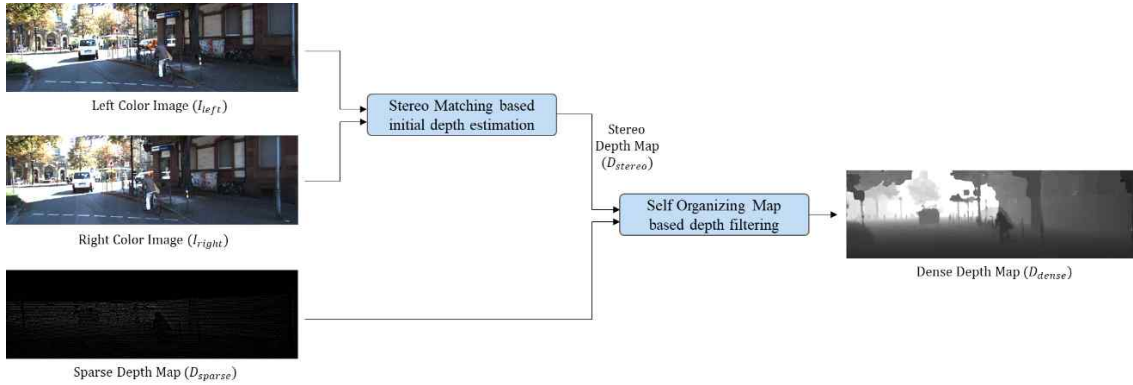


그림 4. 제안하는 방법의 구조도  
 Fig. 4. Diagram of the proposed method

## 2. 기존의 조밀한 깊이 맵 생성 방법

### 2-1. k-최근접 이웃 알고리즘

k-최근접 이웃(k-Nearest Neighbor, k-NN)<sup>[5]</sup> 알고리즘은 포인트와 인접한 k 개의 포인트를 이용하여 대상 포인트를 분류하거나 또는 회귀 분석을 수행하는 방법이다. k-NN 알고리즘 기반의 깊이 예측 과정은 예측 대상 포인트  $x$ 와 거리 기준으로 가까운 k개의 픽셀  $x_i (0 \leq i < k)$ 의 깊이 값을 픽셀 거리 기반 가중평균을 통해  $x$ 의 깊이 값을 예측한다. 수식 2는 k개의 가장 가까운 포인트 및 가중치를 구하기 위한 포인트  $x$ 와  $x_i$ 의 거리 계산을 위한 수식이다.

$$d_i = |x_i - x| \quad (2)$$

수식 3은 k개의 이웃 포인트의 값을 거리에 반비례하도록 가중평균 내어 픽셀  $x$ 의 값을 예측하는 방법을 나타낸다. 여기서  $d_i$ 는  $x_i$ 와  $x$ 의 픽셀 간 거리,  $D(x_i)$ 는  $x_i$ 의 깊이 값,  $D^{KNN}(x)$ 는 k-NN 방법으로 도출된  $x$ 의 깊이 값이다.

$$D^{KNN}(x) = \frac{\sum_{i \in k} \frac{1}{d_i} D(x_i)}{\sum_{i \in k} \frac{1}{d_i}} \quad (3)$$

## 3. 양방향 필터링

양방향 필터링<sup>[10]</sup>을 이용한 깊이 맵 업샘플링 방법은 n개

의 실측 깊이 픽셀을 예측 픽셀과의 거리와 컬러 차이를 기준으로 가중 평균한다. 수식 4는 양방향 필터링을 수행하여 예측 픽셀의 깊이 값  $D^{BF}(x)$ 를 도출하는 수식이다.

$$D^{BF}(x) = \frac{1}{W_p} \sum_{x_i \in \Omega} D(x_i) G_{\sigma_r}(|I(x_i) - I(x)|) G_{\sigma_s}(|x_i - x|) \quad (4)$$

여기서  $D(x_i)$ 는 실측 깊이 픽셀의 깊이 값,  $x, x_i$ 는 각각 예측 깊이 픽셀과 실측 깊이 픽셀 위치,  $I(x), I(x_i)$ 는 예측 깊이 픽셀과 실측 깊이 픽셀에 대응되는 컬러 값이다.  $G_{\sigma_r}$ 과  $G_{\sigma_s}$ 는 각각 컬러 가중치와 거리 가중치이고  $W_p$ 는 모든  $x_i$ 의 가중치의 합이다.  $G_{\sigma_s}$ 와  $G_{\sigma_r}$ 는 가우시안 함수 기반이고 수식 5와 같이 정의된다.

$$G_{\sigma}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (5)$$

## III. 제안하는 조밀한 깊이 맵 생성 방법

본 논문에서는 스테레오 컬러 이미지와 라이다 기반의 희소한 깊이 맵을 이용하여 컬러 이미지와 동일한 해상도의 조밀한 깊이 맵을 생성하는 방법을 제안한다. 그림 4는 제안하는 방법의 전체 수행 과정을 나타낸다. 제안하는 방법은 희소한 깊이 맵( $D_{sparse}$ )에서 깊이 값이 존재하지 않는 위치의 초기 깊이 값을 예측하기 위하여 평행한 위치에서

취득된 스테레오 좌측 이미지( $I_{left}$ )와 우측 이미지( $I_{right}$ )에 대하여 스테레오 매칭을 수행하여 스테레오 깊이 맵( $D_{stereo}$ )을 도출한다. 따라서 초기 조밀한 깊이 맵( $D_{dense}$ )은 최소한 깊이 맵의 실측 깊이 값과 스테레오 깊이 맵의 예측 깊이 값으로 구성된다. 스테레오 깊이 값의 예측 에러를 감소시키고자 각 예측 깊이 픽셀에 대하여 주변의 실측 깊이 픽셀을 이용하여 SOM 기반의 깊이 필터링을 수행하여 최종적으로 조밀한 깊이 맵을 도출한다.

### 1. 스테레오 매칭을 이용한 이미지 기반의 초기 깊이 값 예측

본 장에서는 최소한 깊이 맵에서 깊이 값이 취득되지 않은 위치의 초기 깊이 값을 스테레오 매칭을 기반으로 예측하는 방법을 설명한다. 스테레오 깊이 맵 생성의 첫 번째 단계로 두 장의 이미지에 대하여 스테레오 매칭을 수행하여 시차 영상을 생성한다. 스테레오 매칭이란 기준영상의 한 픽셀이 가리키는 3차원 공간상의 포인트와 동일한 포인트를 가리키는 픽셀을 대상 영상에서 찾는 과정이다. 본 논문에서는 시차 영상 생성을 위하여 OpenCV<sup>[12]</sup>에서 제공하는 스테레오 매칭 기법인 semi-global block matching(SGBM)<sup>[13]</sup>을 이용하였다.

스테레오 매칭 과정에 사용한 KITTI 데이터셋의 두 장의

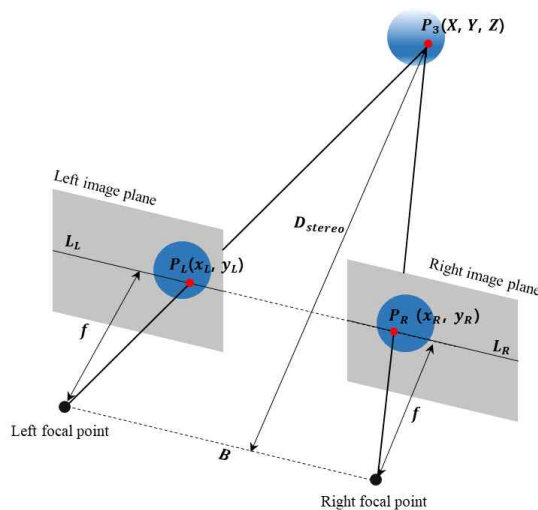


그림 5. 스테레오 이미지 취득 과정  
Fig. 5. Stereo image acquisition process

컬러 이미지는 그림 5와 같이 평행한 위치에서 동시에 취득되었다. 3차원 공간상의 포인트  $P_3$ 은 좌측 카메라 이미지 평면의 픽셀  $P_L$ 에 투영되고, 우측 카메라 이미지 평면의 픽셀  $P_R$ 에 투영된다. 선분  $P_L$ 상의 픽셀에 대응하는 픽셀은 선분  $L_R$ 에 위치하고  $P_R$ 은  $P_L$ 보다 왼쪽에 위치한다. 카메라 설치 환경에 따라서  $P_L$ 과  $P_R$ 의 y축 좌표는 같기 때문에 x축 좌표의 차이 값인 시차  $d$ 를 수식 6와 같이 계산한다.

$$d = x_L - x_R \tag{6}$$

SGBM은 픽셀 당 시차를 얻기 위하여 왼쪽 이미지를 기준으로 오른쪽 이미지에서 대응되는 픽셀을 탐색한다. 오른쪽 이미지의 대응되는 픽셀이 왼쪽 이미지에서의 위치보다 왼쪽에 위치한다는 특성을 이용하여, 최적의 매칭 블록을 탐색하여 시차를 계산한다. SGBM으로 취득한 시차를 수식 7을 이용하여 깊이를 유도하여 스테레오 깊이 맵  $D_{stereo}$ 를 생성한다. 여기서  $f$ 는 초점 거리,  $B$ 는 양쪽 카메라의 초점 간 수평거리,  $d$ 는 시차이다.

$$D_{stereo} = \frac{f \cdot B}{d} \tag{7}$$

### 2. SOM을 이용한 깊이맵 필터링

본 장에서는 3.1 장에서 스테레오 매칭 기반으로 예측한 깊이 값의 예측 오차를 감소시키기 위하여, 주변의 실측 깊이 값을 이용하여 SOM을 기반으로 필터링을 수행하는 방법을 설명한다.

SOM은 비지도 학습을 통해 학습하고자 하는 출력 데이터를 입력 데이터에 대응되도록 군집화를 수행하는 방법이다. 본 논문에서는 SOM을 이용하여 스테레오 예측 깊이 값을 주변의 실측 깊이 실측 깊이 픽셀과의 연결 강도를 고려하여 실측 깊이 픽셀의 깊이 값의 방향으로 업데이트를 반복하는 방법으로 학습을 수행한다. 예측 깊이 픽셀의 초기 값은 스테레오 깊이 맵에서 대응되는 위치의 픽셀  $D_{stereo}(a, b)$ 의 깊이 값으로 지정한다. 그림 6은 실측 깊이 픽셀과 스테레오 예측 깊이 픽셀로 구성된 초기 조밀한 깊이 맵( $D_{dense}$ )과 스테레오 왼쪽 컬러 이미지

( $I_{left}$ )에서 대응되는 위치의 픽셀과 필터링 수행 영역을 나타낸다.  $D_{dense}(i, j)$ 는 임의의 실측 깊이 픽셀, SOM window는  $D_{dense}(i, j)$ 의 필터링 윈도우,  $D_{dense}(a, b)$ 는 SOM window 내 임의의 예측 깊이 픽셀을 나타내고  $I_{left}(i, j)$ 와  $I_{left}(a, b)$ 는 스테레오 왼쪽 컬러 이미지에서 각각  $D_{dense}(i, j)$ ,  $D_{dense}(a, b)$ 에 대응되는 픽셀이다. ( $i, j$ )와 ( $a, b$ )는 각각 실측 깊이 픽셀과 예측 깊이 픽셀의 픽셀 좌표이다.




그림 6. (a) 초기 조밀한 깊이 맵( $D_{dense}$ )에서 임의의 실측 깊이 픽셀 및 필터링 윈도우, (b) 좌측 컬러 이미지( $I_{Left}$ )에서 대응되는 픽셀 및 윈도우  
Fig. 6. (a) Arbitrary measured depth pixel, filtering window in the initial dense depth map ( $D_{dense}$ ), (b) Corresponding pixels and windows in the left color image ( $I_{Left}$ )

초기 조밀한 깊이 맵의 모든 실측 깊이 픽셀에 대하여 각 실측 깊이 픽셀을 중심으로 특정 윈도우 내의 모든 예측 깊이 픽셀에 대하여 깊이 값 업데이트를 수행하고, 해당 과정을 반복하여 수행한다. 예측 깊이 픽셀 값의 업데이트 과정은 수식 8과 같이 수행된다. 예측 깊이 픽셀의 현재 값  $D_{dense}(a, b)_{old}$ 와 실측 깊이 픽셀의 값  $D_{dense}(i, j)$ 의 차이  $d$ 에 두 픽셀의 연결 강도  $\alpha$ 만큼 가중하여 현재 예측 깊이 픽셀 값에 보상해 주어  $D_{dense}(a, b)_{new}$ 를 도출한다. 학습률  $r$ 을 이용하여 학습과정에서 예측 깊이 픽셀이 주변의 다수개의 실측 깊이 픽셀과의 연결강도가 고르게 반영되도록 한다.

가중치  $\alpha$ 는 예측 깊이 픽셀과 실측 깊이 픽셀의 픽셀 간 거리와 색상의 차이를 기준으로 수식 9와 같이 계산된다. 여기서  $SpatialDist$ 는 두 픽셀 간 거리,  $ColorDist$ 는 두 픽셀

간 컬러 차이,  $SpatialVariance$ 는 거리 가우시안 함수의 분산,  $ColorVariance$ 는 컬러 가우시안 함수의 분산이다. 픽셀 간 거리가 가깝고 색상이 비슷할수록 깊이 값의 연관성이 클 것이라고 가정하고, 연관성은 가우시안 분포를 따른다고 가정한다.  $SpatialDist$ 와  $ColorDist$ 는 각각 수식 10과 수식 11와 같이 계산된다. 색상 차이는 RGB 색공간을 CIELAB 색공간으로 변환한 후 계산하였다. CIELAB 색공간의 L은 명도, A는 빨강과 초록의 정도, B는 노랑과 파랑의 정도를 나타낸다. 인간의 시각이 감지하는 색상 차이와 수치적으로 표현한 색상의 차이가 거의 일치하므로 컬러의 차이를 비교하기에 적절한 색공간이다.

$$\alpha = \exp(-(SpatialDist)^2/(SpatialVariance)^2) \cdot \exp(-(ColorDist)^2/(ColorVariance)^2) \quad (9)$$

$$ColorDist = \sqrt{\left( I_{left}(i, j)(L) - I_{left}(a, b)(L) \right)^2 + \left( I_{left}(i, j)(A) - I_{left}(a, b)(A) \right)^2 + \left( I_{left}(i, j)(B) - I_{left}(a, b)(B) \right)^2} \quad (10)$$

$$SpatialDist = \sqrt{(j - b)^2 + (i - a)^2} \quad (11)$$

#### IV. 실험 결과

본 논문에서 제안하는 방법의 성능을 평가하기 위해 Intel i9-10900KF 3.70GHz 프로세서, 64.0GB RAM을 사용하였고 C++ opencv3.4를 이용하여 구현하였다. 기존 연구와 비교를 위하여 Bilateral<sup>[10]</sup>, k-NN<sup>[5]</sup>과 동일한 환경에서 실험하였다. 실험에 사용된 데이터는 KITTI<sup>[14]</sup> depth completion 데이터 셋이다. 데이터 셋은 총 500 프레임에 대하여 제공되고, 한 프레임에 대하여 스테레오 컬러 이미지, 희소한 라이다 깊이 맵, 정답 조밀한 깊이 맵이 제공된다. 제공되는 정답 조밀한 깊이맵은 희소한 깊이 맵에서 깊이 값이 존재하는 픽셀의 약 5배수에 해당하는 픽셀의 정답 깊이 값이 주어진다. 따라서 정답 깊이 값이 존재하는 픽셀에 대하여 깊이 예측 성능을 평가하였다. 데이터 셋은 city,

$$D_{dense}(a, b)_{new} = D_{dense}(a, b)_{old} + r * \alpha * (D_{dense}(i, j) - D_{dense}(a, b)_{old}) \quad (8)$$

residential, road, campus 카테고리 분류되며, 카테고리별로 각 6, 4, 2, 1개의 시퀀스가 제공된다. 그림 7은 성능 평가를 위하여 사용한 데이터의 각 카테고리 별 예시이다. 카테고리 별로 상단부터 순서대로 컬러 이미지, 희소한 라이더 깊이 맵, 정답 조밀한 깊이 맵이다. 표 1은 성능 평가를 위하여 사용한 영상의 목록이다.



그림 7. KITTI 데이터 셋 예시  
Fig. 7. Example of KITTI datasets

표 1. 성능 평가를 위한 KITTI 데이터 셋의 시퀀스 목록  
Table 1. Sequence list of KITTI data set for performance evaluation

Category	Sequence
City	2011_09_26_drive_0002
	2011_09_26_drive_0005
	2011_09_26_drive_0013
	2011_09_26_drive_0095
	2011_09_26_drive_0113
	2011_09_29_drive_0026
Residential	2011_09_26_drive_0020
	2011_09_26_drive_0023
	2011_09_26_drive_0036
	2011_09_26_drive_0079
Road	2011_09_30_drive_0016
	2011_10_03_drive_0047
Campus	2011_09_28_drive_0037

본 절에서는 제안하는 방법과 기존 방법들의 평균 성능을 비교한다. 깊이 예측 정확도의 성능 지표로 MAE(Mean Absolute Error)과 RMSE(Root Mean Square Error)를 사용하였다. 수식 12 와 수식 13은 MAE와 RMSE의 정의식이다. 여기서  $GT_i$ 는 정답 조밀한 깊이 맵의 픽셀이고  $Pred_i$ 는 예측한 조밀한 깊이 맵의 픽셀이다.

$$MAE = \frac{1}{N} \sum_{i=1}^N |I(GT_i) - I(Pred_i)| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (I(GT_i) - I(Pred_i))^2} \quad (13)$$

수식 14, 수식 15는 각각 MAE와 RMSE 측면에서 깊이 예측 오차 감소율에 대한 정의식이다. 여기서  $MAE_{ref}$ 와  $MAE_{proposed}$ 는 각각 기존 방법과 제안하는 방법의 MAE,  $RMSE_{ref}$ 와  $RMSE_{proposed}$ 는 각각 기존 방법과 제안하는 방법의 RMSE다.

$$\Delta MAE = \frac{MAE_{ref} - MAE_{proposed}}{MAE_{ref}} \times 100 \quad (14)$$

$$\Delta RMSE = \frac{RMSE_{ref} - RMSE_{proposed}}{RMSE_{ref}} \times 100 \quad (15)$$

표 2는 제안하는 방법과 기존 방법 k-NN<sup>[5]</sup> 및 Bilateral<sup>[10]</sup>을 MAE, RMSE 측면에서 깊이 예측 성능을 비교한다. 표 3은 기존 방법 k-NN<sup>[5]</sup> 및 Bilateral<sup>[10]</sup> 대비 제안하는 방법의 깊이 예측 성능 향상률을 나타낸다. 표 2와 표 3에서와 같이 제안하는 방법은 k-NN<sup>[5]</sup> 및 Bilateral<sup>[10]</sup> 대비 깊이 예측 오차가 MAE 측면에서 각각 8.69%, 6.46%가 감소되었고, RMSE 측면에서 각각 14.38%, 10.8%가 감소되었다. MAE 측면의 결과는 제안하는 방법이 기존 방법들 대비 깊이 예측의 평균 오차가 감소하였다는 것을 의미한다. RMSE가 측면의 결과는 평균 오차뿐만 아니라 예측 오차의 최대값이 감소하였음을 보인다. 기존 방법들로 깊이 예측 오차가 상대적으로 컸던 영역들에 대하여도 제안하는 방법을 이용하여 예측 오차가 감소하였음을 보인다.



표 2. 제안하는 방법과 기존 방법들의 MAE, RMSE 측면에서의 깊이 예측 성능 비교

Table 2. Comparison of depth prediction performance in terms of MAE and RMSE between the proposed method and the existing methods

	Proposed	k-NN[5]	Bilateral[10]
MAE (mm)	377.67	413.64	403.78
RMSE (mm)	1460.62	1705.95	1637.49

표 3. 기존 방법들 대비 제안하는 방법의 깊이 예측 오차 감소율

Table 3. Depth prediction error reduction rate of the proposed method compared to existing methods

	Proposed - k-NN <sup>[5]</sup>	Proposed - Bilateral <sup>[10]</sup>
$\Delta$ MAE (%)	8.69%	6.46%
$\Delta$ RMSE (%)	14.38%	10.8%

그림 8, 9는 각각 카테고리 City의 “2011\_09\_26\_drive\_0013\_sync\_groundtruth\_depth\_000000014\_image\_02” 프레임, 카테고리 Residential의 “2011\_09\_26\_drive\_0023\_sync\_groundtruth\_depth\_0000000260\_image\_02” 프레임에 대하여 제안하는 방법과 기존 방법들의 주관적 실험 결과 비교를 나타낸다. 그림 8, 9는 모두 각각의 프레임 내에서 객체의 내부 또는 경계 부분에서 라이다로 공간 정보가 취득되지 못한 일부 영역에 대한 결과를 나타낸다. 그림 8, 9의 (a)는 제안하는 방법의 실험 결과, (b)는 k-NN 방법의 실험 결과, (c)는 Bilateral 방법의 실험 결과를 나타내고, (d)는

해당 일부 영역에 대한 스테레오 왼쪽 컬러 이미지, (e)는 최소한 깊이 맵이다. 그림 8의 최소한 깊이 맵에서와 같이, 나무의 우측 경계와 인접하는 배경의 넓은 영역에 대하여 깊이가 취득되지 않았다. 따라서 기존 방법들은 나무의 경계와 인접한 배경 영역의 깊이 값이 나무 영역의 깊이와 유사하게 예측이 되었지만, 제안하는 방법은 해당 배경 영역과 나무의 깊이의 연관성이 적다고 판단하고 스테레오 깊이 값에서 나무의 깊이 값의 방향으로 업데이트가 진행되지 않아서 예측 오차가 더 적다. 그림 9는 그림 8의 경우와 더불어 라이다 취득 시 일부 깊이 값이 취득되지 않는 현상이 빈번하게 발생하는 자동차의 유리 창 또는 표면의 영역에 대해서 제안하는 방법이 기존 방법들 대비 깊이 예측 오차가 적음을 나타낸다.

표 4, 5, 6, 7은 각각 City, Residential, Road, Campus 카테고리 별로 기존 방법들과 제안하는 방법을 MAE, RMSE 측면에서 비교한다. 모든 카테고리에서 기존 방법들 대비 제안하는 방법의 깊이 예측 성능이 높음을 보인다. 각 방법에 대하여 카테고리 간의 성능을 비교하면, 제안하는 방법과 기존의 방법 모두 City, Residential, Road 카테고리 대비 Campus 카테고리에서 가장 낮은 성능을 보인다. Campus 카테고리의 시퀀스는 그림 7에서와 같이 사람, 자전거, 나무 등과 같이 면적이 좁고 형태가 복잡한 객체들이 다수 존재하고 다수 객체들에 빠른 움직임이 존재한다. 라이다

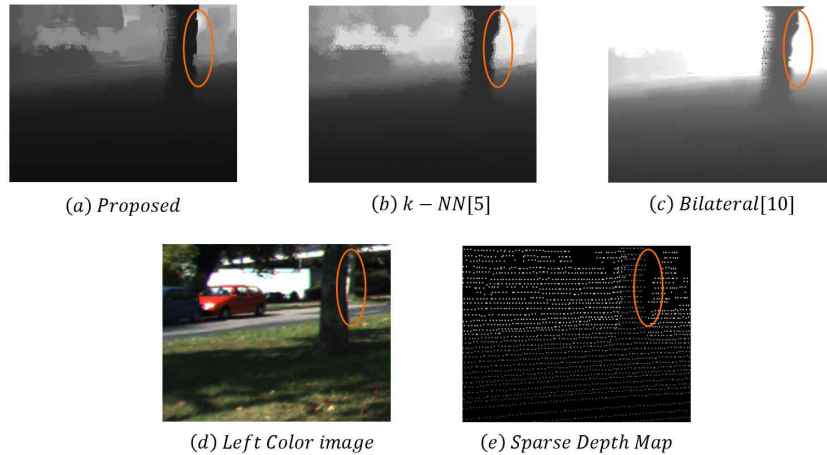


그림 8. “2011\_09\_26\_drive\_0013\_sync\_groundtruth\_depth\_000000014\_image\_02” 프레임의 주관적 실험 결과 비교

Fig. 8. Comparison of subjective experiment results of “2011\_09\_26\_drive\_0013\_sync\_groundtruth\_depth\_000000014\_image\_02” frame

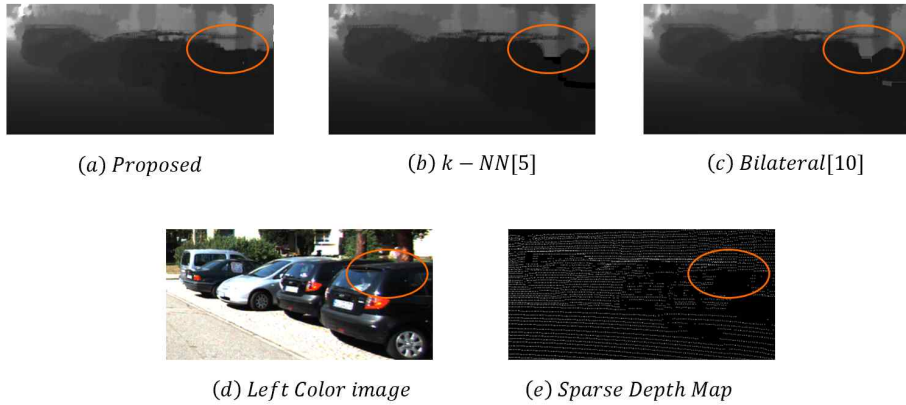


그림 9. "2011\_09\_26\_drive\_0023\_sync\_groundtruth\_depth\_0000000260\_image\_02" 프레임의 주관적 실험 결과 비교

Fig. 9. Comparison of subjective experiment results of "2011\_09\_26\_drive\_0023\_sync\_groundtruth\_depth\_0000000260\_image\_02" frame

표 4. City 카테고리 시퀀스에 대한 기존 방법과 제안하는 방법의 MAE, RMSE 비교

Table 4. Comparison of MAE and RMSE between the existing method and the proposed method for the City category sequence

Method	Measure (mm)	City						Avg.
		2011_09_26_drive_0002	2011_09_26_drive_0005	2011_09_26_drive_0013	2011_09_26_drive_00095	2011_09_26_drive_00113	2011_09_29_drive_0026	
Proposed	MAE	225.96	353.49	417.62	310.65	388.46	369.92	344.35
	RMSE	883.51	1431.60	1630.21	1123.88	1148.03	1646.98	1310.70
k-NN <sup>[5]</sup>	MAE	265.05	375.35	477.23	321.56	407.46	375.49	370.35
	RMSE	1080.45	1598.72	1909.45	1370.07	1275.43	1898.1	1522.03
Bilateral <sup>[10]</sup>	MAE	248.19	368.16	477.44	313.25	401.41	375.79	364.04
	RMSE	1331.78	1533.46	2163.22	1229.61	1151.84	1677.76	1514.61

표 5. Residential 카테고리 시퀀스에 대한 기존 방법과 제안하는 방법의 MAE, RMSE 비교

Table 5. Comparison of MAE and RMSE between the existing method and the proposed method for the Residential category sequence

Method	Measure (mm)	Residential				Avg.
		2011_09_26_drive_0020	2011_09_26_drive_0023	2011_09_26_drive_0036	2011_09_26_drive_0079	
Proposed	MAE	318.46	496.04	403.92	340.56	389.74
	RMSE	1162.23	1957.13	1601.78	1458.41	1544.88
k-NN <sup>[5]</sup>	MAE	336.18	549	448.72	364.84	424.68
	RMSE	1342.86	2308.14	1935.20	1637.57	1805.94
Bilateral <sup>[10]</sup>	MAE	325.57	551.22	439.30	361.36	419.36
	RMSE	1363.33	2301.79	1855.92	1509.88	1757.73

표 6. Road 카테고리 시퀀스에 대한 기존 방법과 제안하는 방법의 MAE, RMSE 비교

Table 6. Comparison of MAE and RMSE between the existing method and the proposed method for the Road category sequence

Method	Measure (mm)	Road		Avg.
		2011_09_30_drive_0016	2011_10_03_drive_0047	
Proposed	MAE	365.77	314.13	339.95
	RMSE	1171.33	1272.40	1221.87
k-NN <sup>[5]</sup>	MAE	406.18	344.59	375.39
	RMSE	1306.86	1455.34	1381.10
Bilateral <sup>[10]</sup>	MAE	386.36	325.77	356.07
	RMSE	1201.75	1334.69	1268.22

표 7. Campus 카테고리 시퀀스에 대한 기존 방법과 제안하는 방법의 MAE, RMSE 비교

Table 7. Comparison of MAE and RMSE between the existing method and the proposed method for the Campus category sequence

Method	Measure (mm)	Campus	
		2011_09_28_drive_0037	Avg.
Proposed	MAE	575.92	575.92
	RMSE	2035.75	2035.75
k-NN <sup>[5]</sup>	MAE	612.075	612.075
	RMSE	2247.07	2247.07
Bilateral <sup>[1]</sup>	MAE	606.94	606.94
	RMSE	2039.54	2039.54

의 해상도가 낮기 때문에 이와 같은 특성을 갖는 영역에 대해서는 취득 시 에일리어싱이 크게 발생할 수 있다. 따라서 주로 단조로운 형태의 자동차, 건물 등의 객체가 다수 존재하는 City, Residential, Road 카테고리 대비 Campus 카테고리에서 깊이 예측 에러가 크게 나타난다.

제안하는 방법과 기존 방법의 윈도우 크기를 동일하게 설정하고 제안하는 방법의 필터링을 한 번만 반복할 경우 필터링 단계에 대한 수행 시간은 거의 동일하지만, 제안하는 방법은 필터링을 반복적으로 수행하기 때문에 반복 횟수가 증가할수록 최종 결과를 도출할 때 까지의 시간이 증가한다. 제안하는 방법에서 업데이트 반복 횟수와 그에 따른 학습률  $r$ 을 조절할 수 있고 이 과정에 따라서 총 수행 시간이 결정된다. 이에 따라서 최종 예측 결과를 도출하기까지는 수행시간이 증가하지만, 임의의 중간 단계의 깊이 예측 결과를 사용할 수 있다는 장점이 있다. 또한 시간적, 공간적으로 순차적으로 취득되는 실측 깊이 값을 취합하여 처리하는 방법이 아닌 취득되는 즉시 예측 깊이 값 업데이트를 진행하여 점진적으로 예측 깊이 오차를 감소시킬 수 있다는 장점이 있다.

## V. 결론

본 논문에서는 라이다 취득 기반의 희소한 깊이 맵을 컬러 이미지의 정보를 함께 이용하여 이미지와 동일한 해상도의 조밀한 깊이 맵을 생성하는 방법을 제안하였다. 라이다에서 공간 정보가 취득되지 않은 영역에 대해서는 깊이

맵에서 깊이 값이 존재하지 않고, 해당 영역에 대하여 깊이 값 예측을 수행하였다. 제안하는 방법은 초기 깊이 값 예측 단계와 깊이 값 필터링 단계가 순차적으로 수행되었다. 초기 깊이 값 예측 단계에서는 두 컬러 이미지에 스테레오 매칭을 수행하여 모든 깊이 예측 대상 픽셀에 대하여 깊이 값을 예측하였다. 깊이 값 필터링 단계에서는 실측 깊이 픽셀 값을 이용하여 주변의 예측 깊이 픽셀의 값의 업데이트를 반복적으로 수행하였다. 업데이트 과정에서 실측 깊이 픽셀과 예측 깊이 픽셀의 깊이 연관도를 픽셀 간 거리와 대응되는 컬러 값의 차이를 기준으로 판단하였다. 주변에 깊이 연관도가 높은 실측 깊이 픽셀이 존재하는 예측 깊이 픽셀들은, 실측 깊이 픽셀 값 방향으로 깊이 값이 필터링되어 예측 오차가 감소되는 효과가 있었다. 주변에 깊이 연관도가 높은 실측 깊이 픽셀이 존재하지 않는 경우에는 가중치가 낮게 유도되어서 실측 깊이 픽셀의 방향으로 업데이트가 진행되지 않지만, 초기 깊이 값으로 사용한 스테레오 깊이 값에 의해 예측 성능이 유지되는 효과가 있었다. 제안하는 방법의 성능 평가를 위하여 KITTI depth completion 데이터 셋을 이용하여 k-NN 및 bilateral 방법과 비교하였다. 제안하는 방법은 양방향 필터 방법 및 k-최근접 이웃 알고리즘 대비 MAE 관점에서 각각 약 6.4%, 8.6%이 감소되었고 RMSE 관점에서 각각 약 10.8%, 14.3%을 감소되는 효과가 있었다.

## 참고 문헌 (References)

- [1] L. Wang, M. Liao, M. Gong, R. Yang, and D. Nister, "High-quality real-time stereo using adaptive cost aggregation and dynamic programming," Third International Symposium on 3D Data Processing, Visualization, and Transmission (3DPVT'06), Chapel Hill, NC, USA, 14-16 June 2006.
- [2] Q. Yang, L. Wang, R. Yang, H. Stewenius, and D. Nister, "Stereo matching with color-weighted correlation," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 31, no.3, pp. 492 - 504, Apr. 2008.
- [3] K.-J. Yoon and I. S. Kweon, "Adaptive support-weight approach for correspondence search," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 28, no. 4, pp. 650 - 656, Apr. 2006.
- [4] J. L. Schonberger and J.-M. Frahm, "Structure-from-motion revisited," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27-30 June. 2016.
- [5] S. B. Imandoust and M. Bolandraftar, "Application of K-Nearest

- Neighbor (KNN) Approach for Predicting Economic Events: Theoretical Background," International Journal of Engineering Research and Applications, vol. 3, no. 5, pp. 605-610, Sep. 2013.
- [6] WG 07 MPEG 3D Graphics coding, "Text of ISO/IEC FDIS 23090-9 Geometry-based Point Cloud Compression," ISO/IEC JTC1/SC29/WG07 N00004, Online, Oct. 2020
- [7] C. Premebida, L. Garrote, A. Asvadi, A. P. Ribeiro, and U. Nunes, "High-resolution LIDAR-based Depth Mapping using Bilateral Filter," 2016 IEEE 19th international conference on intelligent transportation systems (ITSC). IEEE, Rio de Janeiro, Brazil, 1-4 Nov. 2016.
- [8] A. Hirata, R. Ishikawa, M. Roxas, and T. Oishi, "Real-Time Dense Depth Estimation Using Semantically-Guided LIDAR Data Propagation and Motion Stereo," IEEE Robotics and Automation Letters, vol. 4, no. 4, pp. 3806-3811, Oct. 2019.
- [9] N. Schneider, L. Schneider, P. Pinggera, U. Franke, M. Pollefeys, and C. Stiller, "Semantically Guided Depth Upsampling," German Conference on Pattern Recognition 2016, Hannover, Germany, 12-15 Sep. 2016.
- [10] C. Tomasi and R. Manduchi, "Bilateral filtering for gray and color images," Sixth International Conference on Computer Vision, Bombay, India, India, 7-7 Jan. 1998.
- [11] T. Kohonen, "The Self-organizing Map," Proceedings of the IEEE, vol. 78, no. 9, pp. 1464-1480, Sep. 2009.
- [12] G. Bradski and A. Kaehler, Learning OpenCV: Computer vision with the OpenCV library, O'Reilly Media, Inc., 2008.
- [13] H. Hirschmuller, "Stereo Processing by Semi-Global Matching and Mutual Information," IEEE Transactions on pattern analysis and machine intelligence, vol. 30, no. 2, pp. 328-341, Feb. 2008.
- [14] A. Geiger, P. Lenz, C. Stiller, and R. Urtasun, "Vision meets robotics: The kitti dataset," The International Journal of Robotics Research, vol. 32, no. 11, pp. 1231-1237, Aug. 2013.
- [15] J. Jung, Y. S. Ho, "Depth Map Up-sampling Using Maximum Gradient of Color Image", The Korean Society Of Broad Engineers, pp. 29-30, Nov. 2012.
- [16] S. Hong, Y. S. Ho, "Depth Upsampling Method Using Total Generalized Variation," JBE Vol. 21, No. 6, Nov. 2016.
- [17] Y. Ko, H. C. Moon, H. H. Kim, J. G. Kim, "Single-Image Depth Estimation Based on CNN Using Edge Map," The Korean Society Of Broad Engineers, pp. 573-574, Jul. 2020.
- [18] W. Lee, J. Lee, D. Sim, S. Oh, "A Deep Learning based Inter-Layer Reference Picture Generation Method for Improving SHVC Coding Performance," pp. 401-410, JBE Vol. 24, No. 3, May. 2019.
- [19] J. Park, J. Lee, S. Park, D. Sim, "Super Resolution Using Gradient-SR," The Korean Society Of Broad Engineers, pp. 198-199, Jul. 2018
- [20] T. Hui, C. Loy, and X. Tang. "Depth map super-resolution by deep multi-scale guidance," European conference on computer vision, pp. 353-369, Oct. 2016.

---

— 저 자 소 개 —

---



**최 한 술**

- 2018년 2월 : 광운대학교 컴퓨터공학과 학사
- 2020년 2월 : 광운대학교 컴퓨터공학과 석사
- ORCID : <https://orcid.org/0000-0001-7947-0723>
- 주관심분야 : 영상신호처리, 영상압축, 컴퓨터비전



**이 종 석**

- 2016년 2월 : 광운대학교 전자공학과 학사
- 2018년 2월 : 광운대학교 전자공학과 석사
- 2020년 2월 : 광운대학교 컴퓨터공학과 박사과정 수료
- 2020년 2월 ~ 현재 : 디지털인사이드 선임연구원 재직 중
- ORCID : <https://orcid.org/0000-0001-8045-0244>
- 주관심분야 : 영상압축, 스피어킹 심층 신경망, 컴퓨터비전, 고해상도 위성영상 처리

---

저 자 소 개

---



심 동 규

- 1993년 2월 : 서강대학교 전자공학과 공학사
- 1995년 2월 : 서강대학교 전자공학과 공학석사
- 1999년 2월 : 서강대학교 전자공학과 공학박사
- 1999년 3월 ~ 2000년 8월 : 현대전자 선임연구원
- 2000년 9월 ~ 2002년 3월 : 바로비전 선임연구원
- 2002년 4월 ~ 2005년 2월 : University of Washington Senior research engineer
- 2005년 3월 ~ 현재 : 광운대학교 컴퓨터공학과 교수
- ORCID : <https://orcid.org/0000-0002-2794-9932>
- 주관심분야 : 영상신호처리, 영상압축, 컴퓨터비전