

3차원 특징볼륨을 이용한 깊이영상 생성 모델

Depth Map Estimation Model Using 3D Feature Volume

신수연, 김동명, 서재원
충북대학교

Soo-Yeon Shin(ssy8992@cbnu.ac.kr), Dong-Myung Kim(dmkim@cbnu.ac.kr),
Jae-Won Suh(sjwon@cbnu.ac.kr)

요약

본 논문은 컨볼루션 신경망으로 이루어진 학습 모델을 통해 스테레오 영상의 깊이영상 생성 알고리즘을 제안한다. 제안하는 알고리즘은 좌, 우 시차 영상을 입력으로 받아 각 시차영상의 주요 특징을 추출하는 특징 추출부와 추출된 특징을 이용하여 시차 정보를 학습하는 깊이 학습부로 구성된다. 우선 특징 추출부는 2D CNN 계층들로 이루어진 익셉션 모듈(xception module) 및 ASPP 모듈(atrous spatial pyramid pooling) module을 통해 각각의 시차영상에 대한 특징맵을 추출한다. 그 후 각 시차에 대한 특징 맵을 시차에 따라 3차원 형태로 쌓아 3D CNN을 통해 깊이 추정 가중치를 학습하는 깊이 학습부를 거친 후 깊이 영상을 추정한다. 제안하는 알고리즘은 객체 영역에 대해 기존의 다른 학습 알고리즘들 보다 정확한 깊이를 추정하였다.

■ 중심어 : | 깊이영상 | 컨볼루션 신경망 | 딥러닝 | 시차 영상 |

Abstract

This paper proposes a depth image generation algorithm of stereo images using a deep learning model composed of a CNN (convolutional neural network). The proposed algorithm consists of a feature extraction unit which extracts the main features of each parallax image and a depth learning unit which learns the parallax information using extracted features. First, the feature extraction unit extracts a feature map for each parallax image through the Xception module and the ASPP(Atrous spatial pyramid pooling) module, which are composed of 2D CNN layers. Then, the feature map for each parallax is accumulated in 3D form according to the time difference and the depth image is estimated after passing through the depth learning unit for learning the depth estimation weight through 3D CNN. The proposed algorithm estimates the depth of object region more accurately than other algorithms.

■ keyword : | Depth Map | Convolutional Neural Network | Deep Learning | Stereo Image |

*This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (2017R1D1A3B03034476) and research projects of "The Development of Security and Safety Systems based on Ubiquitous Technology for Shipping and Logistics".

접수일자 : 2018년 09월 03일

심사완료일 : 2018년 10월 22일

수정일자 : 2018년 10월 22일

교신저자 : 서재원, e-mail : sjwon@cbnu.ac.kr

I. 서론

최근 3차원 입체 영상에 대한 관심이 급증하면서 고품질의 입체 영상을 생성하기 위한 방법들이 활발하게 논의되고 있다. 그중 깊이영상을 이용하여 임의 시점의 입체 영상들을 합성하는 방법은 제한된 수의 시점영상과 깊이 정보를 이용하여 임의의 시점 영상을 합성하는 것이다. 이에 MPEG 그룹[1]은 다시점 영상 전송 시 소모되는 데이터량을 줄이기 위해 제한된 수의 깊이 영상과 시점영상을 전송한 후 전송 받지 못한 시점의 영상들을 합성 하는 방법을 채택하였다. 따라서 정확한 입체 영상을 얻기 위해 고품질의 깊이영상을 생성하는 방법에 대한 연구들이 수행되고 있다.

깊이영상 생성에 대한 연구들 중 가장 대표적인 방법은 스테레오 정합 (stereo matching)[2-4]을 이용한 깊이값 추정 방법이다. 스테레오 정합을 이용한 깊이값 추정방법은 간단한 블록 기반 화소 위치 정합 알고리즘을 통해 구현할 수 있기 때문에 이를 응용한 많은 연구들이 진행되었다. 하지만 화소 기반 스테레오 정합 방법으로는 정확한 정합 위치를 탐색하기 어렵고 객체나 장면이 가려지는 폐색 (occlusion) 영역이 존재 할 경우 홀 (hole) 문제가 발생하는 단점이 있다. 이에 최근에는 인공 신경망과 같은 딥러닝 모델을 이용하여 기존의 스테레오 정합 방법에서 나타나는 한계점을 극복하고 더욱 정확한 깊이영상을 생성하기 위한 연구가 활발히 진행되고 있다.

MC-CNN (stereo matching cost with a convolutional neural network)[5]은 컨볼루션 신경망 (convolutional neural network)을 이용하는 대표적인 학습 모델이다. 해당 모델은 두 시차 영상에 대해 블록 단위로 특징맵을 추출하고 각 특징맵에 대한 상관성을 계산하는 모든 과정을 학습한다. 이 방법은 가중치 공유를 통한 초기 특징맵 추출 과정을 학습함으로써 각 시차 영상에서 높은 효율을 가지는 비교 특징을 추출할 수 있다. 때문에 기존의 비학습 기법들보다 정확성이 높지만 원본영상을 블록 단위로 쪼개어 깊이를 추정하는 방법이기 때문에 블록 내부에 폐색 영역이 존재할 경우 홀 현상이 일어날 수 있다.

GC-Net (geometry and context network)[6]은 전체 영상을 입력으로 받아 하나의 완전한 깊이영상을 생성하는 모델로 기존의 블록 기반 학습방법들에서 나타나는 문제를 해결하였다. GC-Net은 영상의 전체 영역에 대해 비용볼륨을 생성하고 3차원 컨볼루션을 통해 이를 학습하는 방법으로 전체 깊이영상을 생성한다. 하지만 전체 해상도의 특징맵들로 생성하는 3차원 비용볼륨 파라미터의 크기가 너무 크기 때문에 메모리 소모 및 계산량이 많은 단점이 있다. 이런 GC-Net의 단점을 해결하기 위해 PSM-Net (pyramid stereo matching network)[7]은 초기 특징맵 추출 단계에서 특징맵의 해상도를 입력영상의 1/4배까지 줄여 3D 컨볼루션 층에서 소모되는 메모리량을 줄였다. 또한 3차원 비용볼륨을 생성하기 전에 SPP (spatial pyramid pooling)[8] 모듈을 이용하여 여러 범위의 수용 영역(receptive field)을 포함하는 특징맵을 추출하여 깊이 추정 결과의 정확도를 올렸다. 하지만 SPP를 이용한 특징맵 추출 단계에서 블록 단위 풀링(pooling) 기법을 이용하였기 때문에 버려지는 특징이 많고 복잡도가 높은 영역에 대한 특징이 제대로 추출되지 않는다. 그 결과 추정된 깊이영상에서 국소 영역의 정확도가 떨어진다.

본 논문은 이러한 GC-Net과 PSM-Net의 초기 특징맵 추출단계를 보완한 빠르고 정확한 깊이영상 추정 학습 모델을 제안한다. 본 논문의 구성은 다음과 같다. 우선 2장에서는 제안하는 알고리즘에 대해 구체적으로 소개한다. 3장에서는 제안하는 알고리즘의 깊이영상 생성 결과와 기존 알고리즘들의 결과를 비교하여 보인다. 마지막으로 4장에서는 본 논문에서 제안하는 방법에 대한 간략한 결론을 맺는다.

II. 본론

제안하는 학습 모델의 전체 흐름도는 [그림 2]와 같다. 먼저 특징맵 추출부에서 좌영상과 우영상의 국지적인 특징을 추출한다. 이때 좌영상과 우영상의 특징을 추출하는 단계에서 가중치를 공유하여 동일 조건하에서 각 시차영상의 특징추출을 수행한다. 각 시차에 대

한 특징을 추출한 후, 제안하는 모델은 좌영상의 특징 맵과 우영상의 특징맵을 탐색하려는 시차 범위 만큼 수평으로 이동 (shift) 시키며 하나의 층으로 쌓아 비용볼륨 (cost volume)을 생성한다. 그 후 생성한 비용볼륨을 3차원 컨볼루션 층 (3d convolution layer) 을 통해 학습하고 비용볼륨을 입력영상과 같은 해상도로 업샘플링 한다. 마지막으로 학습된 비용 볼륨에 soft max를 적용하여 각 화소 위치에 대한 깊이값을 추정한다.

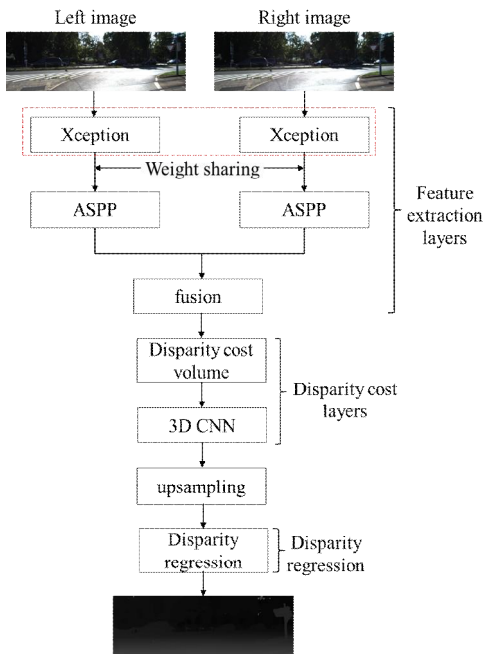


그림 1. 제안하는 깊이영상 생성 모델

1. 특징맵 추출

제안하는 모델은 초기 단계에서 익셉션 모듈[9]과 ASPP 모듈[10]로 이루어진 컨볼루션 층을 통해 특징을 추출한다. 제안하는 모델은 우선 세퍼러블 컨볼루션 (separable convolution)으로 구성된 익셉션 모듈 (xception module)을 이용하여 시차영상의 전체적인 특징들을 효율적으로 추출한다. 기존의 2차원 컨볼루션 층은 특징맵의 가로, 세로 영역과 채널영역에 적용되는 필터를 학습함으로써 공간상의 상관성과 채널간의 상관성을 분리하여 학습하지 않는 반면 익셉션 모듈은

3x3 세퍼러블 컨볼루션을 통해 채널간 상관성을 따로 고려함으로써 학습의 효율성을 높인다. F. Chollet[9]이 제안한 초기버전의 익셉션 모듈은 각 잔차(residual) 학습 블록의 마지막 단에 맥스 풀링(max pooling)을 수행하여 높은 차원의 특징맵을 얻는다. 하지만 이 과정은 가장 높은 값을 가지는 특징 이외의 모든 요소를 버리기 때문에 주요 특징값을 잃을 수 있다. 따라서 제안하는 알고리즘은 맥스 풀링 대신 세퍼러블 컨볼루션을 2 화소 간격(stride)으로 수행하여 고위 정보 특징맵 (high level feature)을 얻는다. 제안하는 익셉션 모듈의 구조는 [그림 2]와 같다.

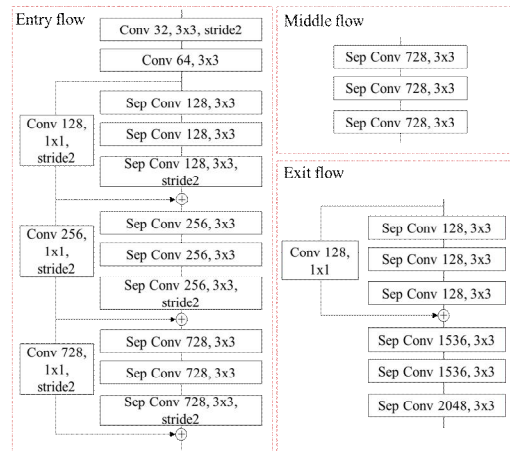


그림 2. 제안하는 Xception 모듈의 순서도

익셉션 모듈을 통해 얻은 단일 계층의 특징맵은 화소의 강도만으로 영역을 추정하기 때문에 맥락을 결정하기 어렵다. 따라서 제안하는 알고리즘은 객체 (예: 나무)와 그 하위 영역 (예: 기둥, 가지, 나뭇잎) 간의 관계를 학습하기 위해 ASPP 모듈을 이용하여 국지적인 특성을 가지는 특징맵을 추출한다. 제안하는 ASPP 모듈은 우선 익셉션 모듈의 최종 결과로 얻을 수 있는 1/16 해상도의 특징맵에 1x1 컨볼루션을 수행하여 해당 해상도의 전체 특징을 가지는 특징맵을 추출하고 하나의 가지 (branch)로 구성한다. 그리고 각각 18, 12, 6으로 팽창 비율(dilation rate)값을 설정한 팽창 컨볼루션 (atrous convolution)을 수행하여 각 팽창 비율 별로 다른 규모와 하위 영역의 정보를 가지는 가지들을 구성된

다. 또한 전역 평균 풀링(global average pooling)을 통해 얻을 수 있는 대표 화소값을 가지로 추가하였다. 제안하는 ASSP 모듈은 일련의 과정을 통해 얻은 각 가지의 특징맵을 모두 적층하고(concatenate) 양선형 보간법(bilinear interpolation)을 통해 입력 영상의 1/16 해상도의 특징맵을 1/4 해상도로 업샘플링한다. 그 후 익셉션 모듈의 초입(entry) 단계에서 얻어지는 1/4 해상도의 특징맵을 업샘플링한 특징맵들과 함께 적층함으로써 고주파 특징 성분의 정확도를 높인다. 제안하는 ASSP 모듈의 구조는 [그림 3]과 같다.

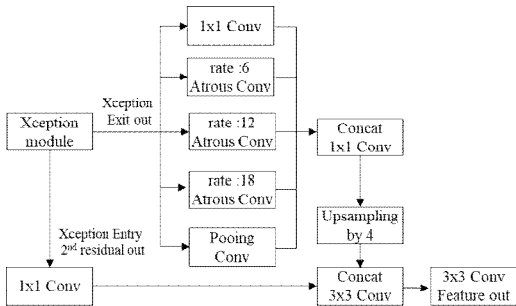


그림 3. 제안하는 ASSP 모듈의 순서도

2. 깊이 비용 학습

깊이 비용 학습 단계에서는 우선 특징 추출 단계에서 얻은 좌우 특징맵을 이용하여 깊이 비용 볼륨을 생성한다. 깊이 비용 볼륨은 가로, 세로의 특징을 가지는 2차원 특징맵에 깊이 정보를 더한 3차원 특징 볼륨이다. 즉, 좌우 특징맵을 각각 깊이 탐색 범위만큼 수평으로 이동시키며 깊이 단위로 쌓아 [가로, 세로, 깊이 탐색 범위]로 이루어진 3차원 볼륨으로 구성한다. 제안하는 모델은 3차원 컨볼루션을 통해 깊이 비용 볼륨의 가로, 세로, 깊이 전 차원을 학습한다. 3차원 컨볼루션은 2차원 컨볼루션에 비해 많은 메모리를 필요로 하지만 제안하는 알고리즘은 특징 추출 단계에서 1/4 해상도까지 다운샘플링한 특징을 추출하여 3차원 컨볼루션에 소모되는 메모리 사용을 최소화하였다.

깊이 비용 학습 단계는 특징맵을 다운샘플링하는 인코더 부분과 다시 업샘플링하는 디코더 부분으로 이루어진 잔차 학습 모델인 hourglass[11]를 3차원 컨볼루

션으로 구성하였다. 제안하는 깊이 비용 학습 모델은 3차원 컨볼루션을 2화소 간격으로 수행하는 다운샘플링 단계와 전치 3차원 컨볼루션 (transposed 3d convolution)을 2화소 간격으로 수행하는 업샘플링 단계를 포함한 총 26층의 3x3x3, 3차원 컨볼루션 층을 통해 깊이 비용 볼륨을 학습한다. 마지막으로 3차원 컨볼루션의 출력은 [가로, 세로, 깊이 탐색 범위, 채널]로 구성된 4차원 볼륨이므로 1x1x1 컨볼루션을 통해 전 채널을 하나로 통합하는 과정을 거친다. 제안하는 알고리즘은 더욱 정확한 깊이맵을 생성하기 위해 이러한 과정을 세 단계에 걸쳐 수행하고 각각의 단계에서 얻어지는 세 개의 특징맵을 깊이영상 생성에 이용한다. 제안하는 3차원 비용볼륨 학습 모델의 구조는 [그림 4]와 같다. 그림에서 직육면체는 한 층에서 얻어지는 특징 볼륨을 의미하며 크기가 서로 다른 특징볼륨은 다운 샘플링 단계와 업샘플링 단계로부터 얻을 수 있는 특징이다. 점선으로 이어진 부분은 잔차 학습을 위한 숏컷(short cut)을 의미한다.

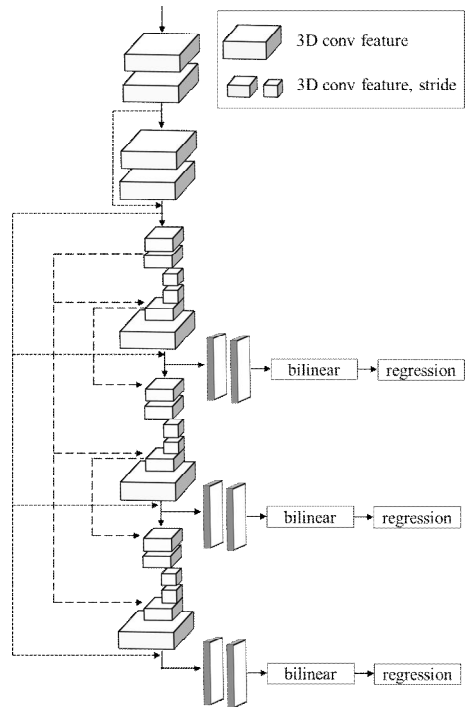


그림 4. 제안하는 3차원 깊이 비용 모듈의 순서도

3. 깊이 추정

제안하는 알고리즘은 GC-Net에서 제안한 SRM (soft argument min) 과정을 이용하여 깊이 추정을 수행한다. SRM 과정은 우선 깊이 비용 계산 단계에서 얻은 깊이 비용에 음수를 취한 후 softmax()를 수행하여 각 깊이에 대한 확률 비용을 구한다. 그 후 0에서 사이의 모든 시차 범위에 대해 해당하는 확률비용 $\delta(-c_d)$ 와 시차값 d 를 곱하여 더해줌으로써 2차원 깊이영상을 생성한다. SRM의 수식은 다음과 같다.

$$\text{soft argmin} = \sum_{d=0}^{D_{\max}} d \times \delta(-c_d) \quad (1)$$

4. 손실 함수

제안하는 모델은 후버 손실(huber loss) 함수를 통해 손실값을 계산하고 가중치를 업데이트한다. 후버 손실 함수는 기존의 자승법 기반 손실함수를 기반으로 제안된 방법으로 단순히 예측값과 실제 관측값 사이의 차이를 손실로 적용하는 기존의 손실함수들과는 달리 신뢰 구간을 설정하여 민감도가 낮은 손실값을 적용적으로 구한다. 제안하는 알고리즘은 후버 손실 함수의 신뢰 구간을 1로 설정하여 원본 영상의 화소 x_i 와 예측 영상의 화소 y_i 사이의 화소값 차이가 1보다 크면 화소값 차이를 제곱한 값에 0.5를 곱하고 1보다 작으면 화소값 차의 절대값을 0.5로 뺀 값을 출력한다. 제안하는 모델의 손실 함수는 다음수식과 같다.

$$L(x, y) = \begin{cases} \frac{1}{N} \sum_{i=1}^N 0.5(x_i - y_i)^2, & \text{if } |x_i - y_i| < 1 \\ \frac{1}{N} \sum_{i=1}^N |x_i - y_i| - 0.5, & \text{otherwise} \end{cases} \quad (2)$$

III. 실험 결과

1. 실험 환경

제안하는 모델은 Tensorflow로 구현하였으며 GPU 환경에서 학습 및 테스트를 수행하였다. 학습을 위해 Adam optimizer를 통하여 경사하강을 수행하였으며

learning rate는 0.001로 β_1 과 β_2 는 각각 0.9, 0.999로 설정하였다. 학습과정에서 입력 배치(batch)는 가로 H는 256, 세로 W는 512 크기로 랜덤하게 입력하였고 깊이 탐색 범위 D_{\max} 는 192로 설정하였다. 또한 학습 및 실험을 위한 영상 데이터로 35454장의 스테레오 영상을 제공하는 SceneFlow[12] 데이터 셋과 200장의 스테레오 영상을 제공하는 KITTI[13] 데이터 셋을 사용하였다.

2. 결과 비교

[표 1]은 제안하는 학습모델과 기존의 학습모델인 MC-CNN[5], GC-Net[6], PSM-Net[7]의 실험결과를 보여준다. 해당 표에서 극단치(outlier rate)는 원본 깊이값과의 차이가 3이상인 화소의 개수를 백분율로 표시한 수치다. 또한 Bg(back ground)는 영상의 배경부분만을 포함하는 결과이고 Fg(foe ground)는 배경을 제외한 객체 영역만을 포함한 결과이며 Allg(All ground)는 전체 영역에 대한 결과를 나타낸다.

표 1. 깊이영상 생성 결과 오류 극단치 비교

데이터 셋	알고리즘	극단치 (>3px)		
		Bg	Fb	Allg
실험 영상1	MC-CNN	0.23	2.62	2.11
	GC-Net	1.40	1.24	1.38
	PSM-Net	1.61	0.42	1.44
	Proposed	1.71	0.80	1.59
실험 영상2	MC-CNN	2.90	5.06	3.14
	GC-Net	2.20	3.80	2.38
	PSM-Net	1.96	2.22	1.99
	Proposed	1.64	3.41	1.84
실험 영상3	MC-CNN	7.43	8.12	7.49
	GC-Net	5.29	3.41	5.12
	PSM-Net	3.67	1.16	3.45
	Proposed	3.61	0.89	3.37
영상 200장에 대한 평균	MC-CNN	2.89	8.88	3.89
	GC-Net	2.21	6.16	2.87
	PSM-Net	1.86	4.62	2.32
	Proposed	2.13	4.57	2.54

실험 결과 제안하는 모델의 결과가 MC-CNN과 GC-Net보다 확연히 좋은 성능을 보였다. 또한 평균적인 결과에서는 PSM-Net보다 떨어지는 결과를 보였지만 객체 영역에 한정해서는 PSM-Net 보다 좋은 성능을 보였다.

[그림 5]와 [그림 6]은 각각 실험 영상1과 실험 영상2에 대한 각 알고리즘의 결과이다. 붉은색으로 표현된 부분은 원본 영상과 각 알고리즘에 의해 생성된 화소 차이가 3보다 큰 지점이다. 실험 결과 배경 영역의 비중이 큰 [그림 5]의 경우 PSM-Net이 제안하는 모델보다 오류픽셀의 수가 적다는 것을 알 수 있다. 반면에 전방 객체 영역의 비중이 큰 test image 2의 경우 제안하는 알고리즘이 오류 화소의 수가 적다는 것을 알 수 있다. 이는 제안하는 알고리즘의 특징 추출 단계인 ASPP 모듈이 PSM-Net의 SPP 모듈에 비해 전방 영역의 국소 특징을 효율적으로 추출하기 때문이다.




그림 5. 각 모델을 통해 생성한 깊이영상의 오류화소

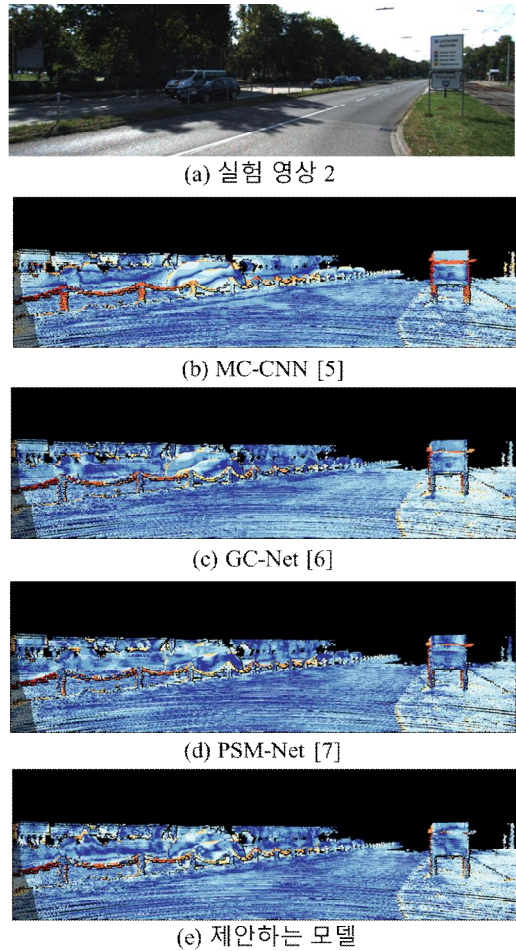


그림 6. 각 모델을 통해 생성한 깊이영상의 오류화소

[표 2]는 한 장의 KITTI 테스트 영상에 대한 깊이영상을 생성하는데 소요되는 시간을 비교한 표이다. 실험 결과 MC-CNN보다 약 63.12초 정도 빠르고 GC-Net 보다는 약 0.02초가량 빠르다는 것을 확인할 수 있었다.

표 2. KITTI 깊이영상 생성 시 장당 수행시간 비교 (s)

MC-CNN	GC-Net	PSM-Net	Proposed
64	0.9	0.41	0.88

IV. 결론

제안하는 ASPP 모듈을 이용한 깊이영상 생성 모델은 두 장의 시차 영상을 입력으로 받아 깊이영상의 전체 화소값을 추정한다. 제안하는 모델은 ASPP 모듈을 통해 각 시점별 초기 특징맵을 추출한 다음 이를 통합하여 3차원 깊이 비용 볼륨을 생성하고 깊이영상을 추정하는 모든 과정을 학습한다. ASPP 모듈을 이용하여 여러 범위를 포함하는 특징을 추출한 결과, 전방 객체 및 배경을 포함하는 모든 영역에 대해서 MC-CNN과 GC-Net에 비해 정확한 깊이 성능을 보였다. 비록 PSM-Net에 비해 배경 영역의 정확도는 높지 않았지만 전방 영역의 경우 제안하는 알고리즘의 정확도가 높은 것을 확인할 수 있었다. 가까울수록 시차값이 커지고 객체가 도드라지는 입체영상의 특성상 먼곳에 존재하는 배경의 거리 정보보다는 가까운 객체의 거리 정보가 중요하다. 때문에 제안하는 알고리즘의 성능을 PSM-Net 보다 좋게 평가 할 수 있다. 또한 인코더-디코더 방식을 통해 1/16배 까지 특징맵을 줄여 학습을 수행한 결과, PSM-Net을 제외한 다른 알고리즘 보다 수행속도가 빠른 것을 확인할 수 있었다.

참 고 문 헌

- [1] ISO/IEC JTC1/SC29/WG11, "Application and Requirements on FTV," N9466, 2007.
- [2] C. Stentoumis, L. Grammatikopoulos, I. Kalisperakis, and G. Karras, "On accurate dense stereo-matching using a local adaptive multi-cost approach," ISPRS J. of Photogrammetry and Remote Sensing, Vol.91, pp.29-49, 2014.
- [3] A. Miron, S. Ainouz, A. Rogozan, and A. Bensrhair, "A robust cost function for stereo matching of road scenes," Pattern Recognition Letters, Vol.38, pp.70-77, 2014.
- [4] C. Stentoumis, L. Grammatikopoulos, I. Kalisperakis, and G. Karras, "Stereo matching based on census transformation of image gradients," in Proceeding of the SPIE Optical Metrology, International Society for Optics and Photonics, 2015.
- [5] J. Zbontar and Y. Lecun, "Stereo matching by training a convolutional neural network to compare image patches," International J. of Machine Learning Research, Vol.17, pp.1-32, 2016.
- [6] A. Kendall, H. Martirosyan, S. Dasgupta, P. Henry, R. Kennedy, A. Bachrach, and A. Bry, "End-to-end learning of geometry and context for deep stereo regression," in Proceeding of the IEEE International Conference on Computer Vision (ICCV), pp.1-8, 2017.
- [7] J. R. Chang and Y. S. Chen, "Pyramid Stereo Matching Network," in Proceeding of the IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), pp.5410-5418, 2018.
- [8] K. He, X. Zhang, S. Ren, and J. Sun, "Spatial pyramid pooling in deep convolutional networks for visual recognition," in European Conference on Computer Vision, pp.346-361, 2014.
- [9] F. Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions," in Proceeding of the IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [10] L. C. Chen, G. Papandreou, L. Kokkinos, K. Murphy, and A. L. Yuille, "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs," in Proceeding of the IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [11] A. Newell, K. Yang, and J. Deng, "Stacked hourglass networks for human pose estimation," in European Conference on Computer Vision, pp.483-499, 2016.

[12] N. Mayer, E. Ilg, P. Hausser, P. Fischer, D. Cremers, A. Dosovitskiy, and T. Brox, "A large dataset to train convolutional networks for disparity, optical flow, and scene flow estimation," in Proceeding of the IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2016.

[13] M. Menze and A. Geiger, "Object Scene Flow for Autonomous Vehicles," in Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2015.

서 재 원(Jae-Won Suh)

정회원



- 1995년 2월 : 충북대학교 전자공학(공학사)
- 1997년 2월 : 광주과학기술원 정보통신학과(공학석사)
- 2003년 2월 : 광주과학기술원 정보통신학과(공학박사)

- 2003년 4월 ~ 2004년 8월 : LG전자기술원 MM연 선임 연구원
- 2004년 9월 ~ 현재 : 충북대학교 전기전자컴퓨터공학부 부교수

<관심분야> : 디지털 영상신호처리, 동영상 표준화, H.264/AVC, SVC, HEVC

저 자 소 개

신 수 연(Soo-Yeon Shin)

정회원



- 2011년 2월 : 충북대학교 전자공학(공학사)
- 2013년 2월 : 충북대학교 전자공학(공학석사)
- 2013년 3월 ~ 현재 : 충북대학교 전자공학과 박사과정

<관심분야> : 디지털 영상신호처리, 멀티미디어, 딥러닝, 깊이영상

김 동 명(Dong-Myung Kim)

준회원



- 2015년 2월 : 충북대학교 전자공학(공학사)
- 2017년 2월 : 충북대학교 전자공학(공학석사)
- 2017년 3월 ~ 현재 : 충북대학교 전자전공 박사과정

<관심분야> : 디지털 영상신호처리, 멀티미디어, 딥러닝