

# 스테레오 깊이 영상의 신뢰도 추정 기술 동향


□ 김선옥 / 한국항공대학교

## 요약

3차원 깊이 영상은 시점으로부터 객체까지의 거리와 관련된 정보를 제공하는 영상으로 최근 자율주행 자동차, 스마트 드론, 로보틱스, 증강 현실, 의료 영상 등에 핵심 정보로 활용되는 매우 중요한 정보이다. 이에 따라 컴퓨터 비전 분야에서는 2차원 영상으로부터 3차원 깊이 정보를 획득하는 연구가 계속되어 왔고, 최근 인공지능 기술의 발달에 힘입어 그 성능도 나날이 향상되고 있다. 그 중에서도 스테레오 영상 간의 매칭을 통하여 깊이 정보를 획득하는 스테레오 매칭 기술은 데이터베이스 구축이 비교적 용이하고 획득 환경이 제한적이지 않다는 장점으로 인해 널리 활용되고 있다. 하지만 텍스처가 없는 영역, 패턴이 반복되는 영역, 가림 영역 등에서 성능에 한계를 보이기 때문에, 깊이 영상의 신뢰도를 추정하는 스테레오 깊이 영상의 신뢰도 추정 기술을 이용하여 깊이 정보를 효과적으로 복원할 수 있다. 본 고에서는 스테레오 매칭을 통하여 획득한 깊이 영상의 신뢰도 추정 기술의 발전 동향을 살펴보고 현재 기술의 한계점과 향후 나아갈 방향에 대해서 토의한다.

## 1. 서론

2차원 영상에서 초정밀 3차원 깊이 정보를 획득하는 문제는 컴퓨터 비전 및 영상 처리 분야의 오랜 목표 중 하나로서 자율주행 자동차, 스마트 드론, 로보틱스, 가상현실, 증강현실, 3차원 장면 이해 등과 같은 다양한 적용 분야에서 활용될 수 있는 핵심 요소 기술이다. 3차원 깊이 정보 획득을 위해서는 크게 능동형(Active) 센서와 수동형(Passive) 기법을 이용하는 방법이 있다. 능동형 센서는 Time-of-Flight(ToF) 카메라 또는 LiDAR 센서 등을 이용하여 깊이 값을 직접적으로 획득하는 방법으로 감지 범위가 제한적이고 획득 환경의 제한성과 고비용으로 인하여 정확한 깊이 정보를 획득하기 어렵다는 한계를 가진다. 반면 수동형 기법으로는 대표적으로 다중 영상으로부터 깊이 정보를 획득하는 스테레오 매칭 방법이 있는데, 이는 텍스처가 없는 영역, 패턴이 반복되는 영역, 가림 영역 등에서 성능이 현저히 떨어진다



<그림 1> 스테레오 영상과 스테레오 매칭으로 구한 깊이맵의 한계점

는 문제점이 있다(그림 1).

최근, 딥러닝을 포함한 인공지능 기술의 발전으로 스테레오 매칭 방법을 기계 학습 문제로 정의하고 보다 정확한 깊이 영상을 구하고자 하는 시도가 계속되고 있지만, 스테레오 매칭이 가지는 내재적인 문제점 때문에 여전히 제한적인 성능을 보이고 있다. 이를 해결하기 위하여 스트레오 매칭을 통하여 획득한 깊이 정보의 신뢰도를 추정하여 깊이 영상을 보정하는 기술이 연구되고 있다(그림 2). 스테레오 깊이 영상의 신뢰도 추정 방법은 스트레오 매칭을 통해 획득한 깊이 영상을 입력으로 하여 깊이 값의 신뢰도를 출력함으로써 보다 높은 신뢰도를 가진 깊이 값을 이용하여 깊이 영상을 보정하는 기술이다. 본 고에서는 스테레오 깊이 영상의 신뢰도 추정

과 최신 기술 동향을 살펴보고자 한다.

II장에서는 스테레오 신뢰도 추정 기술을 수작업(Hand-crafted) 방식과 딥러닝에 기반한 방법에 대해 살펴본 후, 딥러닝을 이용한 스테레오 신뢰도 추정 최신 연구를 소개한다. III장에서는 다양한 데이터베이스에 대한 신뢰도 추정 기술 결과를 비교하고, 마지막으로 IV장에서 결론을 맺는다.

## II. 스테레오 신뢰도 추정 기술 동향

이번 장에서는 스테레오 깊이 영상의 신뢰도 추정 두 가지 방법으로 나누어 자세히 살펴보고자 한다. 먼저 수



<그림 2> 스테레오 매칭으로 추정된 깊이 영상과 이에 대한 신뢰도맵

작업(Hand-crafted) 기반의 신뢰도 추정 기술을 살펴 보고, 최신 학습(learning) 기반의 신뢰도 추정 기술에 대해 소개한다.

### 1. 수작업 기반의 신뢰도 추정 방법

스테레오 깊이 영상의 신뢰도 추정을 위해서 단일 모달리티(modality)로부터 하나의 단일 특징자(single feature)를 이용하여 신뢰도를 추정하는 기술이 연구되어왔다[1,2]. 이는 크게 세 종류의 입력으로 구분 가능하다. 먼저, 스테레오 매칭 시 같은 좌영상 혹은 우영상을 참조(reference) 영상을 중심으로 한 픽셀씩 옮겨가며 픽셀 혹은 패치간의 유사도를 계산한 코스트(cost)를 쌓아서 만든 코스트볼륨(cost volume)으로부터 유의미한 신뢰도 특징자(confidence feature)를 계산할 수 있다(그림 3).

대표적인 메트릭으로는 코스트가 가장 낮은 지점에서의 값을 이용하는 매칭 스코어(Matching Score Measure, MSM)가 있다. 매칭 스코어를 이용하여 픽셀 p에서의 신뢰도 특징자를 다음과 같이 구할 수 있다.

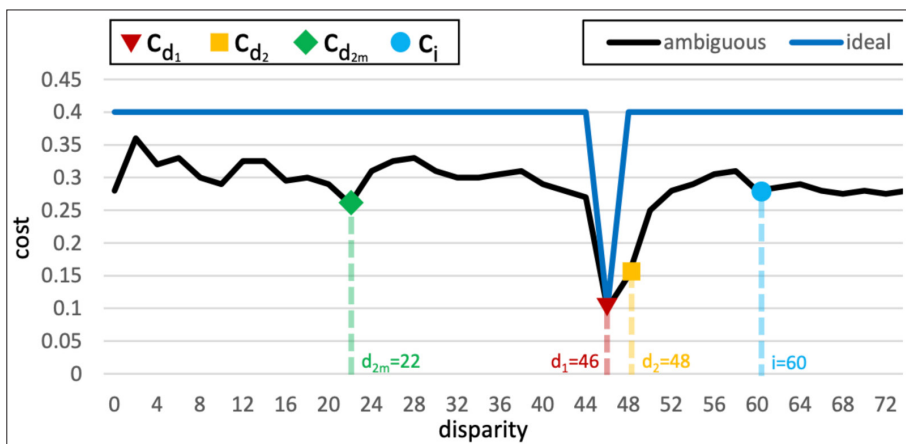
$$MSM(p) = -c_{d_1}(p)$$

또 다른 대표적인 특징자로는 전역최저점(minimum cost)과 지역최저점(local minima)의 비율을 이용한 피크 래시오 (Peak Ratio, PKR)가 있으며 다음 식을 이용하여 구한다.

$$PKR(p) = \frac{c_{d_{2m}}(p)}{c_{d_1}(p)}$$

다음으로는 추정된 깊이 영상을 입력으로 신뢰도 특징자를 계산할 수 있다. 대표적으로는 좌우 일관성(left-right consistency)을 통하여 좌우 깊이 영상에서 획득한 깊이 값을 이용하여 컬러 영상에서의 픽셀 값이 일치하는지 확인하는 방식이다. 또는 깊이 영상 패치의 분산(Variance of the disparity)이 있는데, 이는 패치 내에서 깊이값이 일관되지 않은 경우 낮은 신뢰도를, 일관된 깊이값을 가질수록 높은 신뢰도를 부여하는 방식이다.

마지막으로는 컬러 영상을 입력으로 신뢰도 특징자를 계산하는 방법이 있다. 컬러 영상의 경사도(gradient) 정보 등을 이용한 영상 엣지까지의 거리(Distance to



<그림 3> 특정 픽셀에서의 스테레오 매칭 코스트 그래프,  $C_{d_1}$ : 전역최저점,  $C_{d_2}$ : 두번째 전역최저점,  $C_{d_3}$ : 지역최저점. ([2]에서 발췌)

image edge) 또는 컬러 영상 패치 내의 분산을 이용한 분산 추정(Intensity variance)을 통한 신뢰도 계산이 가능하다.

위와 같이 단일 모달리티의 입력으로부터 단일 특징자를 이용하여 신뢰도를 추정하는 기술은 특징자를 정의하는 방법에 따라서 성능이 크게 좌우된다. 단일 특징자는 그 특징이 모두 다르기 때문에 스테레오 매칭을 통해 생성되는 깊이 영상 패치의 특징을 모두 표현하기에 한계가 있다. 이러한 한계를 극복하기 위하여 단일 특징자를 여러 개 결합하여 고성능의 신뢰도 추정 특징자를 만드는 기술이 연구되었다[3,4].

먼저, [3]에서는 다양한 모달리티의 입력으로부터 23개의 단일 특징자를 정의하고, 이를 모두 결합한 23차원의 벡터(vector)를 새로운 신뢰도 특징자로 정의하여 그 성능을 크게 향상시켰다. 그렇지만 이 방법 또한, 23개의 단일 특징자가 사전에 정의되어 있기 때문에 다른 스테레오 추정 기술을 사용하거나 데이터의 특성이 달라지는 경우에도 고정된 종류의 신뢰도 특징자를 그대로 사용해야한다는 단점이 있다.

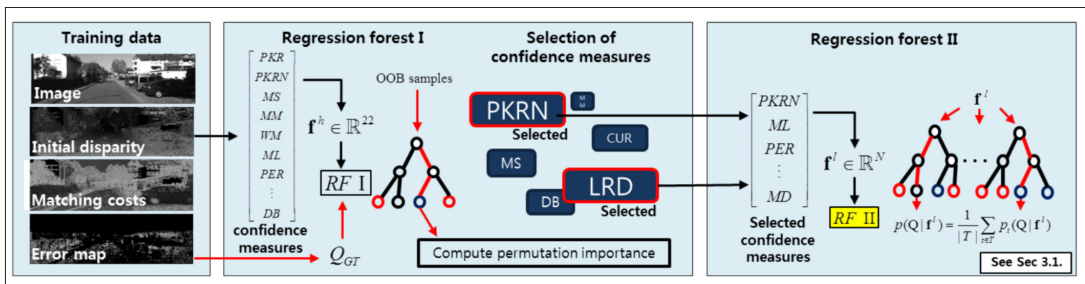
## 2. 학습 기반의 신뢰도 추정 방법

이를 극복하기 위한 방법으로 학습을 통하여 신뢰도 특징자를 정의하고 신뢰도를 추정하는 기술이 연구되

어왔다. 초기에는 <그림 4>와 같이 다양한 종류의 단일 특징자를 정의하고 신뢰도를 학습하는 과정에서 랜덤 포레스트(Random forest)와 같이 얇은 분류기(shallow classifier)를 이용하여 최적의 특징자셋(set)을 찾은 후에, 이를 결합한 새로운 신뢰도 특징자를 정의하였다. 이러한 방법을 통해 특정 스테레오 추정 기술 혹은 데이터셋에 대한 최적의 신뢰도 특징자를 찾을 수 있다.

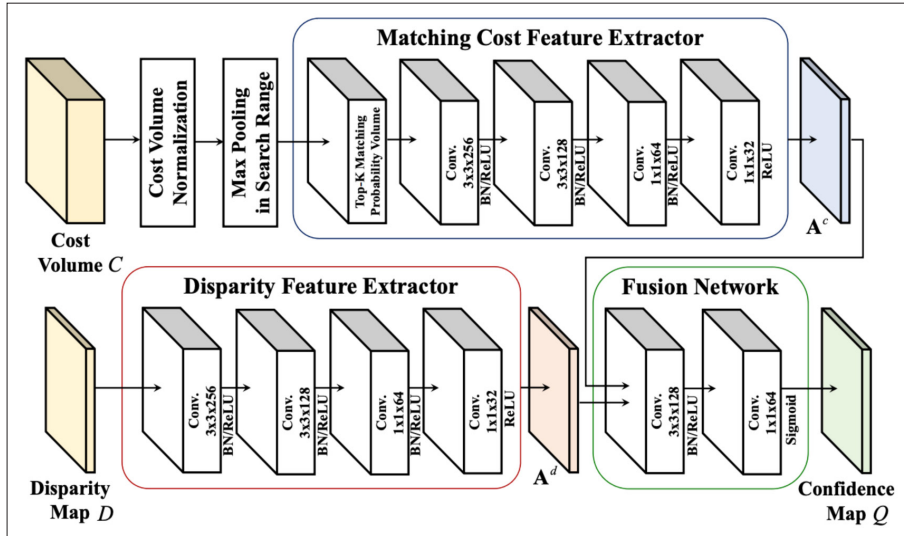
하지만, 분류기 성능의 한계로 인하여 제한적인 성능을 보이며, 학습할 때 이용하지 않은 새로운 스테레오 추정 기술이나 데이터셋을 이용하는 경우 또 다시 학습해야하는 문제점이 있다. 최근에는 인공지능과 딥러닝 기술의 발전으로 인해, 고성능의 분류 성능을 가진 분류기가 연구되고 있으며[5,6], 이를 신뢰도 추정에 적용한 기술을 소개하고자 한다.

먼저, [7]에서는 딥러닝을 통하여 단일 깊이 영상을 입력으로 하고 정답 신뢰도맵(ground truth confidence map)을 출력으로 하는 크로스 엔트로피 손실 함수(cross entropy loss)를 이용하여 신뢰도 추정 네트워크를 학습하였다. 이를 통해 신뢰도 추정 성능을 크게 향상시켰지만, 여전히 단일 모달리티의 입력으로 인해 제한적인 성능을 보인다. 이를 극복하기 위하여, 다중 모달리티(multi modality) 입력으로부터 신뢰도 특징자를 생성하는 기술이 연구되었다[8,9].

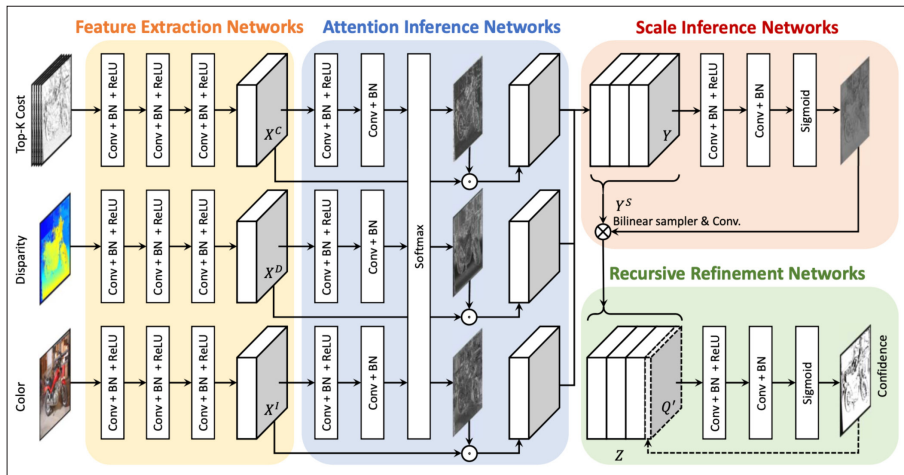


<그림 4> 랜덤 포레스트를 이용하여 최적의 신뢰도 특징자셋을 찾는 과정([4]에서 발췌)





<그림 5> 다중 모달리티 입력을 이용한 깊이 영상 신뢰도 추정 네트워크([8]에서 발췌)



<그림 6> 지역적 어텐션을 이용한 다중 모달리티 기반 깊이 영상 신뢰도 추정 네트워크([9]에서 발췌)

[8]에서는 <그림 5>와 같이 먼저 코스트 볼륨과 깊이 영상을 각각 입력으로 하는 매칭 코스트 특징 추출 네트워크(Matching cost feature extractor)와 깊이 특징 추출 네트워크(Disparity feature extractor)를 구성하고 특징자를 추출한 후, 두 특징자를 결합(concatenation)하는 결합 네트워크(Fusion network)를 통해 새로운

신뢰도 특징자를 생성하고 이를 통해 신뢰도를 추정하였다.

더욱 효과적인 다중 입력 특징자 융합을 위하여, LAF-Net[9]에서는 픽셀마다 각 입력의 가중치를 다르게 주는 방식을 채택하여 특징자를 결합한다. 먼저 코스트, 깊이 영상, 컬러 영상으로 구성된 다중 모달리티 입력으로부터

터 특징 추출 네트워크(Feature extraction networks)를 거쳐서 특징자를 추출한 후, 각 입력의 가중치를 추정하는 가중치 추정 네트워크(Attention inference networks)를 통과시켜 각 픽셀 혹은 패치에서 중요도가 더 큰 모달리티에 더 큰 가중치를 할당한다. 또한, 스케일 추정 네트워크(Scale inference networks)와 재귀 보정 네트워크(Recursive refinement networks)를 통하여 신뢰도 추정 성능을 향상시킨다(그림 6)).

### III. 신뢰도 추정 기술 성능 비교

이번 장에서는 다양한 신뢰도 특징자에 대한 신뢰도 추정 결과를 살펴보고자 한다. 깊이 영상 성능을 위해 널리 사용되는 데이터셋으로는 KITTI[10] 데이터셋

과 Middlebury[11] 데이터셋이 있다. 신뢰도 추정 정확도는 정답 깊이 영상(ground-truth disparity)과 추정된 깊이 영상(estimated disparity)와의 절대적인 차이(absolute difference)가 임계 값(threshold)보다 크면 신뢰도를 0으로, 임계 값보다 작으면 신뢰도를 1로 하여 만든 정답 신뢰도맵(ground-truth confidence map)을 이용하여 추정한다.

평가 메트릭으로는 신뢰도가 가장 낮은 픽셀을 지워가면서 정답 깊이 영상과 추정된 깊이 영상 간의 배드매칭 에러(Bad Matching Error, BMP)를 계산한 후에 이를 밀집 정도(sparsity)에 따라 나타낸 그래프인 밀집 정도 그래프(sparsity curve)를 사용한다. 밀집 정도 그래프의 면적을 수치화한 AUC(Area Under Curve)를 이용하여 평가를 진행하는데, 이 때 정답 신뢰도맵을 이용하여 측정한 AUC가 최적값(Optimal)이 된다.

<표 1> MCCNN-SGM [12] 으로 추정된 깊이 영상에 대한 수작업 기반 신뢰도 추정 결과. ([2]에서 발췌)

	Driv.	2012	2015	Midd.	ETH	R.		Driv.	2012	2015	Midd.	ETH	R.
APKR <sub>5</sub>	10.88	0.86	1.57	6.05	4.03	4	DA <sub>15</sub>	18.31	2.65	3.18	7.63	3.20	17
APKR <sub>5</sub>	17.75	2.48	2.73	8.44	4.82	22	DMV	18.18	2.43	2.90	10.37	6.27	31
CUR	17.14	2.84	2.93	9.65	6.62	29	DS <sub>15</sub>	15.01	1.43	2.08	6.93	3.76	12
DAM	23.16	5.26	5.19	17.97	10.73	44	DTD	11.39	2.26	1.89	12.46	7.76	20
LC	16.53	3.05	3.09	10.14	7.52	32	MDD <sub>21</sub>	15.82	2.40	2.61	12.18	5.93	28
MM	10.60	1.11	1.94	6.95	5.26	8	MND <sub>21</sub>	12.49	1.62	1.84	9.86	4.92	14
MMN	17.98	3.08	3.04	10.10	6.26	33	SKEW <sub>21</sub>	12.31	1.97	2.36	10.84	7.71	19
MSM	13.30	0.88	1.96	6.09	3.59	7	VAR <sub>17</sub>	10.11	0.78	1.22	6.97	3.64	2
NLM	10.60	1.11	1.94	6.95	5.26	9	ACC	19.09	3.21	3.58	14.01	9.20	36
NLMN	17.98	3.08	3.04	10.10	6.26	34	LRC	20.04	3.58	4.08	14.92	9.08	38
PKR	10.51	0.88	1.65	5.93	4.19	3	LRD	14.52	1.69	2.28	7.50	5.15	15
PKRN	15.34	2.11	2.38	8.07	5.05	16	UC	19.31	3.40	3.70	14.48	9.60	37
SGE	13.12	0.81	1.86	5.96	3.41	6	UCC	13.10	1.06	1.99	6.37	3.70	10
WPKR <sub>5</sub>	10.91	0.90	1.64	6.19	4.11	5	UCO	21.17	4.40	4.60	15.94	9.74	40
WPKRN <sub>5</sub>	17.63	2.86	3.05	9.05	5.05	26	ZSAD	15.53	5.39	4.69	15.94	10.36	39
ALM	12.45	1.87	2.69	12.78	7.79	25	DTS	24.67	15.47	7.42	28.52	14.30	48
LMN	23.28	3.15	3.75	11.34	5.73	35	DSM	13.35	6.96	2.98	7.17	4.67	18
MLM	12.22	1.75	2.58	12.13	7.53	21	SAMM	11.56	7.90	2.14	11.73	6.44	30
NEM	17.66	4.38	4.43	18.24	12.03	41	DB	22.39	5.07	5.61	19.43	8.96	43
NOI	30.79	12.18	8.88	26.70	15.41	49	DLB	22.45	3.64	4.34	18.25	9.98	42
PER	12.43	1.86	2.67	12.69	7.75	24	DTE	29.67	5.73	6.13	22.40	10.59	47
PWCEFA	11.85	1.45	2.18	8.33	6.33	13	HGM	27.25	5.57	5.72	21.04	11.17	45
WMN	10.91	0.81	1.58	5.45	3.33	1	IVAR <sub>5</sub>	30.37	5.22	5.90	21.06	9.74	46
WMNN	13.80	1.33	2.03	6.53	4.07	11	SCS	16.50	2.40	3.17	9.11	5.14	23
PS	15.83	2.33	2.83	9.88	7.46	27							
Opt. D1(%)	4.57	0.25	0.44	2.94	1.41	-	Opt. D1(%)	4.57	0.25	0.44	2.94	1.41	-
	26.92	6.08	6.03	21.80	12.59	-		26.92	6.08	6.03	21.80	12.59	-

<표 2> MCCNN-SGM[12]으로 추정된 깊이 영상에 대한 학습 기반 신뢰도 추정 결과([2]에서 발췌)

	Train set: Driving							Train set: KITTI 2012					
	Driv.	2012	2015	Midd.	ETH	R.	CR.	2012	2015	Midd.	ETH	R.	
ENS <sub>23</sub>	8.40	1.40	1.97	8.45	5.97	18	15	ENS <sub>23</sub>	0.82	1.64	7.94	5.39	17
GCP	9.00	1.37	1.66	12.33	6.57	19	20	GCP	1.00	1.91	7.53	5.61	18
LEV <sub>22</sub>	8.29	1.26	1.71	7.78	4.83	17	11	LEV <sub>22</sub>	0.81	1.37	8.43	4.13	13
LEV <sub>50</sub>	7.60	1.06	1.51	6.75	4.23	11	5	LEV <sub>50</sub>	0.75	1.15	6.46	3.92	3
FA	7.07	2.54	2.38	10.60	6.83	5	21	FA	1.08	1.33	7.76	5.50	16
ENS <sub>7</sub>	9.41	2.15	2.59	9.64	6.11	21	18	ENS <sub>7</sub>	1.27	1.82	9.84	6.55	21
O1	7.48	1.70	2.09	8.10	5.04	10	14	O1	0.80	1.21	6.46	5.03	10
O2	7.34	1.59	2.15	7.84	4.82	9	13	O2	0.72	1.07	6.24	5.36	9
CCNN	8.05	1.64	2.05	10.10	4.74	16	16	CCNN	0.89	1.22	7.64	5.11	14
PBCP <sub>r</sub>	9.74	0.91	1.40	5.98	3.33	23	1	PBCP <sub>r</sub>	0.86	1.25	6.09	5.07	7
PBCP <sub>d</sub>	7.76	1.41	1.98	6.74	3.25	15	4	PBCP <sub>d</sub>	1.08	1.44	12.71	12.18	22
EFN	9.40	3.26	3.52	11.45	6.42	20	22	EFN	1.27	1.41	9.52	4.71	19
LFN	7.67	2.66	2.96	10.60	5.34	13	19	LFN	0.99	1.17	7.75	5.35	15
MMC	7.24	1.60	1.99	8.34	4.26	6	12	MMC	0.93	1.11	7.01	4.75	12
ConfNet	7.31	1.16	1.81	8.40	3.31	8	8	ConfNet	0.87	1.36	6.93	3.40	5
LGC	7.03	1.15	1.76	7.56	3.76	4	6	LGC	0.85	1.10	6.87	4.83	11
RCN	11.40	1.83	2.86	15.58	9.46	24	24	RCN	1.02	2.52	22.54	12.38	24
MPN	7.30	1.43	1.60	5.99	3.85	7	2	MPN	0.63	1.14	6.76	3.82	4
UCN	7.01	1.23	1.63	6.22	3.80	3	3	UCN	0.67	1.19	6.32	3.54	2
LAF	6.21	0.99	1.76	6.88	5.96	1	10	LAF	0.61	1.21	6.01	3.72	1
ACN	6.81	1.59	2.00	6.46	4.28	2	7	ACN	0.63	1.22	7.31	3.83	6
CRNN	9.54	1.30	2.21	16.61	9.38	22	23	CRNN	0.98	2.24	21.80	12.20	23
CVA	7.62	1.61	2.23	9.49	5.36	12	17	CVA	0.77	1.49	8.61	6.06	20
SGMF	7.71	1.72	1.53	6.64	4.85	14	9	SGMF	0.83	1.83	6.46	4.25	8
Opt.	4.57	0.25	0.44	2.94	1.41	-	-	Opt.	0.25	0.44	2.94	1.41	-
D1(%)	26.92	6.08	6.03	21.80	12.59	-	-	D1(%)	6.08	6.03	21.80	12.59	-

<표 1>과 <표 2>는 MCCNN-SGM 스테레오 매칭 기법 [12]을 이용하여 추정된 깊이 영상에 대하여 각각 수작업 기반의 신뢰도 추정 방법과 학습 기반의 신뢰도 추정 방법의 결과를 보여준다.

학습 기반의 신뢰도 추정 기술이 수작업 기반의 신뢰도 추정 기술과 비교하였을 때 더욱 뛰어난 성능을 보여주고 있음을 알 수 있다. 단일 모달리티 입력은 제한적인 성능을 보이는 반면, 다중 모달리티 입력은 신뢰도 추정에 효과적인 특징자를 더욱 잘 생성해냄을 알 수 있다.

#### IV. 결론

본 고에서는 인공지능 기술을 이용하여 스테레오 매

칭을 통해 획득한 깊이 영상의 신뢰도를 추정하는 기술 동향에 대해 살펴보았다. 과거 수작업 기반으로 신뢰도 추정자를 사전에 정의하는 방식에 비해 최근 딥러닝 기반의 신뢰도 추정 기술은 다중 모달리티 입력을 이용하여 추정된 깊이 영상에 대한 최적의 특징자를 효과적으로 학습함으로써 신뢰도 추정 성능을 향상시켰다. 그렇지만 여전히 새로운 특성을 가진 데이터에 대해서는 데이터에 맞게 학습을 하는 과정이 필요하기 때문에 이를 극복할 수 있는 방안이 필요한 실정이다. 또한, 현재까지는 정답 신뢰도맵을 구축하여 지도학습 기반으로 신뢰도를 추정하였으나 데이터베이스 구축에 한계를 가지기 때문에, 정답 신뢰도맵이 없는 경우 준지도학습이나 비지도 학습을 적용하는 기술을 연구한다면 신뢰도 추정 기술 성능이 향상될 것이라고 기대된다.

## 참고 문헌

- [1] X. Hu and P. Mordohai, "A quantitative evaluation of confidence measures for stereo vision," IEEE Trans. Pattern Anal. Mach. Intell., 2012.
- [2] M. Poggi, S. Kim, F. Tosi, S. Kim, F. Aleotti, D. Min, K. Sohn, and S. Mattoccia, "On the confidence of stereo matching in a deep-learning era: a quantitative evaluation, IEEE Trans. Pattern Anal. Mach. Intell., 2022.
- [3] R. Haeusler, R. Nair, and D. Kondermann, "Ensemble learning for confidence measures in stereo vision," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., 2013.
- [4] M. Park and K. Yoon, "Leveraging stereo matching with learning-based confidence measures," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., 2015.
- [5] A. Krizhevsky, S. Ilya, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," Advances in neural information processing systems, 2012.
- [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," In Proceedings of the IEEE conference on computer vision and pattern recognition, 2016.
- [7] M. Poggi and S. Mattoccia, "Learning from scratch a confidence measure," in Proc. Brit. Mach. Vis. Conf., 2016.
- [8] S. Kim, D. Min, B. Ham, S. Kim, and K. Sohn, "Deep stereo confidence prediction for depth estimation," in Proc. IEEE Conf. Image. Process., 2017.
- [9] S. Kim, S. Kim, D. Min, and K. Sohn, "Laf-net: Locally adaptive fusion networks for stereo confidence estimation," In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019.
- [10] M. Menze and A. Geiger, "Object scene flow for autonomous vehicles, in Proc. IEEE Conf. Comput. Vis. Pattern Recognition, 2015.
- [11] D. Scharstein, H. Hirschmuller, Y. Kitajima, G. Krathwohl, N. Nestic, X. Wang, and P. Westling, "High-resolution stereo datasets with subpixel-accurate ground truth," in Proc. German Conf. Pattern Recognit., 2014.
- [12] J. Zbontar and Y. LeCun, "Computing the stereo matching cost with a convolutional neural network," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., 2015.

## 필자 소개



### 김선옥

- 2009년 ~ 2014년 : 연세대학교 전기전자공학과 학사
- 2014년 ~ 2019년 : 연세대학교 전기전자공학과 박사
- 2019년 ~ 2021년 : 연세대학교 박사후연구원
- 2021년 ~ 현재 : 한국항공대학교 소프트웨어학과 조교수
- 주관심분야 : 컴퓨터비전, 인공지능, 3차원 영상처리