

Optical Flow 추정 기술 및 최신 연구 동향

김영민 (인천대학교), 안현욱 (고려대학교), 김진평 (차세대융합기술연구원)

목 차

1. 서 론
2. Optical Flow 활용 사례
3. 전통적인 Optical Flow 추정
4. 딥러닝 기반의 Optical Flow 추정
5. Optical Flow 추정 방법 및 비교 분석
6. 결 론

1. 서 론

자율주행 시장 규모가 2035년 743조원까지 성장할 것으로 전망[1]되고, 전 세계 지능형 CCTV 시장 규모는 2015년부터 연평균 78.6%의 고성장을 이루고 있다[2]. 자율주행과 지능형 CCTV 분야에서 보행자의 움직임 분석(Motion Analysis)을 통해서 보행자의 안전을 위한 연구가 활발히 진행되고 있다[3,4].

이러한 움직임 분석 방법은 많은 방법 중 Optical Flow 방법을 통해 의미론적인 해석이 가능하여 주로 이용한다[5]. Optical Flow란 관찰자와 장면 사이에서 상대적인 움직임으로 인해 시각적 장면에서 물체 등의 명백한 움직임의 패턴을 말한다[6]. 이 패턴은 이미지에서 연속한 두 프레임(frame) 사이에서 각 픽셀(pixel)의 움직임을 나타내는 벡터를 의미하고 이 값을 통해 움직임을

추정할 수 있다. Optical Flow의 추정은 Optical Flow 제약식 기반의 계산(전통적 방식)으로 이뤄졌지만 2015년 이후 딥러닝 기반의 Optical Flow 추정을 할 수 있게 되었다.

본 논문에선 Optical Flow를 활용한 사례에 대해서 다루고, 전통적인 Optical Flow 추정 방법과 딥러닝을 활용한 추정 방법을 소개 및 비교한다.

2. Optical Flow 활용 사례

Optical Flow 추정은 주로 객체의 움직임 추정 및 객체 추적으로 활용된다. Optical Flow는 이뿐만 아니라 많은 분야에서 응용되고 활용되고 있다.

의료 분야에서는 Optical Flow를 이용하여 심근 세포 수축성을 식별[7]하고 초음파 영상은 Optical Flow 기반으로 보간(interpolation)하여 더욱 정확한 초음파 영상 분석을 이뤄내고 있다

[8]. 또한, Optical Flow를 이용하여 고품질의 MRI 영상을 만드는 기법도 활용되고 있다[9].

교통 분야에서도 자율주행 자동차 분야에 Optical Flow가 많이 활용된다. 자율주행 자동차의 원활한 운영을 위해 보행자 움직임을 추정하거나, 도로 위의 장애물을 탐지하기 위한 연구도 진행되고 있다[10-11]. 또한, CCTV 영상을 기반으로 차량 통행량과 차량의 속도를 추정을 이뤄내고, 교통에서의 차선 이탈, 불법 유턴과 같은 이상 상황을 탐지하는 연구도 진행된다[12-13].

마지막으로 로봇 분야에서는 드론에서 지상 물체를 탐지하고 추적하기 위해 Optical Flow를 활용하고, 자동으로 충돌을 회피하기 위한 방법으로도 활용된다[14-15].

3. 전통적인 Optical Flow 추정

Optical Flow의 제약조건은 흐름 벡터로 이어진 두 픽셀의 값은 동일하다라는 것이다. 이러한 제약조건을 식 (1)을 이용하여 계산한다. 식 (1)에서 I 는 이미지를 의미하고, x, y 는 이미지에서의 픽셀 좌표의 위치, t 는 프레임 시간을 의미한다. 그리고 u 는 x 방향으로 움직임, v 는 y 방향으로 움직임을 의미한다.

$$I(x, y, t) = I(x + u, y + v, t + 1) \quad (1)$$

식 (1)의 우항에 테일러 근사(Taylor-Approximation)를 이용하면

$$\frac{dI}{dx} \delta x + \frac{dI}{dy} \delta y + \frac{dI}{dt} \delta t = 0 \quad (2)$$

식 (2)가 도출이 되고 이를 δt 로 나누면 식 (3)과 같은 Optical Flow 방정식이 도출된다.

$$\frac{dI}{dx} u + \frac{dI}{dy} v + \frac{dI}{dt} = 0 \quad (3)$$

식 (3)은 부정방정식의 형태로 이를 풀기 위해 선 주변 픽셀의 정보를 이용하여 Optical Flow를 계산해야 한다. 이를 계산하는 방법은 크게 두 가지로 나뉘는데 첫 번째로 일부의 픽셀을 이용하여 부분적으로 계산(Sparse Optical Flow)을 하는 방식이다. 그리고 두 번째로 이미지의 모든 픽셀들을 이용하여 계산(Dense Optical Flow)하는 방식이 있다.

Sparse Optical Flow는 이미지의 일부 픽셀만 이용하여 Optical Flow를 추정하는 것이다. 주로 이미지의 모서리와 같은 주요 특징점 픽셀을 기반으로 Optical Flow를 추정한다. 전체 픽셀에 대한 계산이 아니라 일부의 픽셀 부분만 계산하기 때문에 연산 속도가 빠른 장점이 있지만 추정 정확도는 낮은 단점이 있다. 대표적인 알고리즘으로 Lucas-Kanade 알고리즘[16]을 발전시킨 Lucas-Kanade Pyramid 알고리즘[17]이 있다.

반면에 Dense Optical Flow는 이미지의 모든 픽셀들에 대하여 계산하여 모든 픽셀에 대한 Optical Flow를 추정한다. 모든 픽셀들에 대해서 계산을 하기 때문에 연산량이 증가하여 추정 속도는 느리지만 Sparse Optical Flow에 비해 정확한



(그림 1) Lucas-Kanade 적용 예시



(그림 2) Farneback 적용 예시

장점이 있다. 대표적인 알고리즘으로 Farneback 알고리즘이 있다[18].

(그림 1)은 Shi-Tomasi[19] 방법으로 주요 특징 점을 추출하고 Lucas-Kanade Pyramid 방식으로 Optical Flow를 추출한 그림이고, (그림 2)는 Farneback 알고리즘으로 Optical Flow를 추정한 그림이다.

4. 딥러닝 기반의 Optical Flow 추정

딥러닝을 이용하여 Optical Flow를 추정하기에는 Optical Flow의 실제 정답 값(Ground Truth)이

있는 데이터셋의 부족이라는 문제점이 있었다. 2015년 이전의 구축된 데이터셋은 딥러닝을 통해 훈련 시키기에는 매우 적었으며 Optical Flow의 정답값을 갖고 있는 데이터셋도 적었다. 하지만 FlowNet[20] 저자가 발표한 Flying Chairs 데이터셋 이후로 많은 데이터셋들이 구축되면서 딥러닝을 활용한 Optical Flow 추정 기술이 많은 발전을 이뤘다. Optical Flow를 추정하기 위한 데이터셋 종류는 <표 1>과 같다.

4.1 FlowNet


FlowNet은 최초의 딥러닝 기반으로 Optical Flow를 추정하는 알고리즘이다. FlowNet을 바탕으로 하여 FlowNet2.0[27], LiteFlowNet[28] 등의 여러 알고리즘으로 발전하였다.

FlowNet은 CNN을 기반으로 Optical Flow를 추정하고 FlowNet-Simple(FlowNet-S), FlowNet Corr (FlowNet-C)라는 알고리즘을 제안하였다. FlowNet-S와 FlowNet-C의 구조 그림은 (그림 3)과 같다.

FlowNet-S는 두 이미지를 합친 값(concat)을 이용하여 Optical Flow를 추정하는 것이고,

<표 1> Optical Flow 추정을 위한 데이터셋 종류

데이터셋 이름	프레임 쌍	데이터셋 구축 연도	특징
Middlebury[21]	72	2011	정답값이 존재하는 프레임의 수가 8개로 매우 적음
Sintel[22]	1,041	2012	안개나 블러링(blurring)의 유무에 따라 데이터셋이 나뉨
KITTI2012[23]	194	2013	움직임이 없는 부분은 포함하지 않음
Flying Chairs	22,872	2015	Flickr 데이터셋에 3D chairs[24] 이미지를 합성한 데이터셋
Flying Things3D[25]	25,000	2016	3D 데이터셋으로 구조화된 배경과 랜덤한 물건의 움직임을 이미지
Playing benchmarks[26]	254,064	2017	많은 양의 고해상도 데이터셋




(그림 3) (상) FlowNet-S, (하) FlowNet-C

FlowNet-C는 각 두 이미지의 특징(feature)을 추출한 뒤 이를 correlation layer에 통과시킨 후 컨볼루션(Convolution) 연산을 반복하여 Optical Flow를 추정한다. Correlation Layer는 두 이미지에 대하여 이미지 픽셀의 상관도를 계산함으로써 추정 정확도를 높이는 방법이다. 그리고 Refinement Layer를 통해서 손실 값을 계산하면서 신경망의 정교한 업데이트를 할 수 있는 방법을 고안하였다.

4.2 PWC-Net

PWC-Net[29]은 피라미드형의 CNN을 기반으로 한다. 그리고 SpyNet[30]의 피라미드 방식과 이미지 왜곡 방식[31], Cost-Volume[32] 방식을 모두 사용한 네트워크이다. PWC-Net은 SpyNet과 비슷한 점이 많지만 주요한 차이점을 두어 SpyNet보다 좋은 성능을 내었다. PWC-Net은 SpyNet과 달리 피라미드를 통과한 이미지 자체가 아닌 특징 맵을 warping 층에 통과시킨다. 그리고 SpyNet은 프레임을 바로 CNN에 통과시키지만

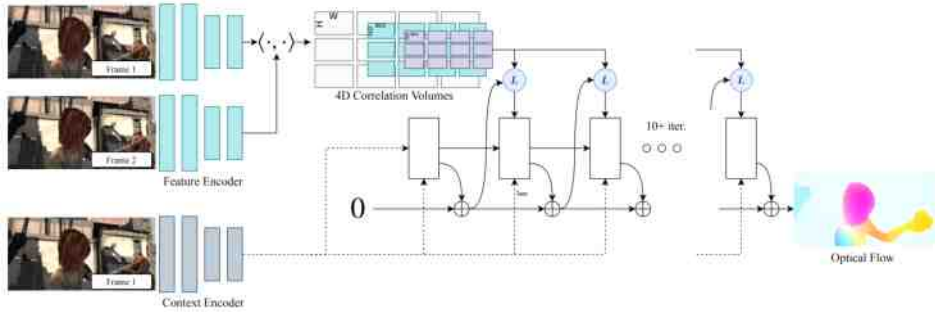
PWC-Net은 Cost-Volume 층을 거치고 CNN을 통해 Optical Flow를 추정한다. 이때, Cost-volume 층은 FlowNet-C의 Correlation Layer를 따른다. PWC-Net의 구조는 (그림 4)와 같다. PWC-Net은 많은 방법을 조합하여 end-to-end 방식으로 학습 가능하게 설계하였다. 이로 인해 Sintel-final 데이터셋에서 당시 가장 적은 에러율을 기록하였다.



(그림 4) PWC-Net 네트워크 구조

4.3 RAFT

RAFT[33]는 반복을 활용하여 Optical Flow의 정확한 추정을 이뤄낸다. RAFT의 구조는 (그림 6)과 같다. RAFT는 크게 3가지 부분으로 나눌 수



(그림 5) RAFT 네트워크 구조

있는데, 특징 추출 부분과 4D correlation volume 부분과 GRU[34] 부분으로 나눌 수 있다.

특징 추출 부분은 두 부분으로 나뉘지는데, Fnet과 Cnet으로 나뉜다. Fnet은 움직임을 추정하기 위한 특징들을 추출하는 부분이고, Cnet은 이미지의 맥락(context)을 추출하는 부분인데 이는 사람의 손과 머리 등을 구분하는 특징들을 추출하는 것이다. 맥락 추출은 첫 번째 이미지에 대해서만 수행을 한다.

4D correlation volume은 픽셀 간의 유사도를 측정하기 위한 층이다. 기존의 correlation volume과 동일한 방식으로 계산하고 쌍선형 다운샘플링(Bilinear Downsampling)을 하여 피라미드 형태로 만들어서 각 크기별 Correlation volume을 구할 수 있게 된다. 이는 식 (4)로 나타낼 수 있다.

$$C^k : [H \times W \times \frac{H}{2^k} \times \frac{W}{2^k}] \quad (4)$$

이러한 과정은 Optical Flow를 추정하는 반복이 시행되기 전에 단 한 번만 진행이 된다. 따라서 연산 속도가 줄어든다는 점을 해결하였다. 반복 중에는 Correlation Lookup 연산이 이뤄지는데 이는 4차원의 cost volume을 3차원의 cost volume으로 치환해주는 과정이다.

Cost volume을 GRU 구조에 넣어서 반복 계산을 하고 컨볼루션 연산을 거쳐서 최종적인 Optical Flow를 추정할 수 있게 된다.

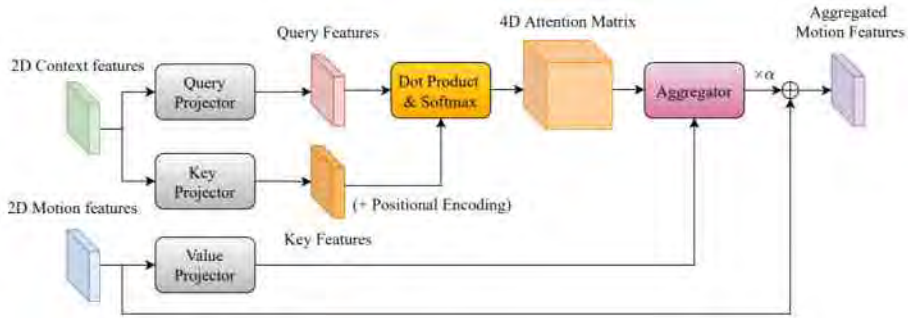
RAFT는 또한, warm-start 방식[35]을 제안하면서 전 프레임에서 계산된 Optical Flow들의 벡터를 미리 이동한 값을 초기값으로 설정한다. warm-start 방식을 사용함으로써 기존의 모델들보다 비약적으로 좋은 성능을 내었다.

4.4 GMA

GMA[36]는 RAFT 모델을 기반으로 이미지 겹침(Occlusion)으로 인해 Optical Flow의 추정이 불가능한 문제를 해결한 모델이다. 이러한 문제를 기존 프레임의 자기 유사도를 이용하여 이미지 겹침 문제를 해결한다.

Optical Flow 추정에서 이미지 겹침 문제는 기존에 sfM-Net[37], MaskFlowNet[38] 등에서도 효율적인 처리를 위한 연구가 계속되었다. 특히, MaskFlowNet은 Occlusion Mask라는 개념을 도입하여 이미지 겹침이 있어도 겹침에 대한 학습이 가능하도록 하여 이미지에 대한 손실을 줄였다.

GMA는 이를 넘어서 이미지 겹침 영역에 대한 손실 문제 해결뿐만 아니라 장거리 연결의 Optical Flow의 추정을 이뤄냈다. GMA 모듈의 기본 가정



(그림 6) GMA 모듈 구조

은 네트워크가 참조 프레임에서 비슷한 모양의 포인트를 찾아 유사한 모션(motion)의 포인트를 추론할 수 있다는 것이다. 이는 단일 객체에 대한 포인트의 움직임이 주변의 움직임과 유사하다는 통계적 편향이 있다는 것에 기반한다. 따라서 GMA 모듈은 이러한 가정을 기반으로 가려지지 않은 픽셀에서 가려진 픽셀로 값을 전파하는 방법이다. GMA 모듈 부분은 (그림 6)과 같다.

GMA 모듈은 전체 구조 중 일부으로써 트랜스포머(Transformer)[39]를 기반으로 어텐션 모듈을(attention module) 이용하여 장거리 의존성 모델링을 할 수 있게 구성하였다. GMA는 4D correlation layer에서 특징점을 추출한 값에서 쿼리(query)와 키(key) 투영기(projector)를 통과시키면서 프레임 1의 자체 유사성을 추출한다. 그리고 이를 4D 어텐션 행렬(4D attention matrix) 계산하여 모션의 숨겨진 값을 집계한다. 그리고 집계한 값에 값 투영기(value projector)를 거친 값도 합쳐서 부분 모션 특징을 추출할 수 있다.

5. Optical Flow 추정 방법 비교 및 분석

<표 2>는 Optical Flow 추정 모델별로 정리한 표이다. EPE(End-Point-Error)는 Optical Flow 추정의 성과지표로 식 (5)와 같이 정의된다.

$$EPE = \sqrt{(u - u_{GT})^2 + (v - v_{GT})^2} \quad (5)$$

u 와 v 는 각각 수평 성분과 수직 성분의 계산된 Optical Flow, u_{GT} 와 v_{GT} 는 실제 Optical Flow를 나타내고 이를 모든 프레임에 대해 평균을 취한 것이 AEPE(Average-End-Point-Error)가 된다.

전통적인 방법은 주변 픽셀들만 이용하여 계산하는 기법에서 다운스케일링(Downscaling)과 가중치 모델 개선과 같은 주변 픽셀들의 계산 방법 개선을 통하여 정확성을 높였으며, 최근 기법에서는 역연산을 활용하거나 그리드 형태를 이용하여 정확성을 더 높인 것을 확인할 수 있다.

반면 딥러닝 방법은 FlowNet이 처음으로 Optical Flow를 추정하였으며, 이 모델을 개선하여 정확도를 향상시켰으며, 최근 기법은 Mask를 활용하여 훈련 방법을 개선하거나 cost volume를 사용하여 cost 함수를 개선하여 정확성을 비약적으로 발전시켜 전통적인 방법보다 훨씬 더 높은 정확성을 보이는 것을 확인할 수 있다.

(그림 7)은 맨 왼쪽이 정답값, 그리고 순서대로 EpicFlow, FlowNet2.0, GMA 알고리즘을 적용한 Sintel-clean 데이터셋의 시각화 결과이다. 시각화는 HSV 형태로 나타내며 색상은 방향을 표현하고, 채도는 크기를 나타낸다.

〈표 2〉 Optical Flow 추정 모델별 AEPE 비교(Sintel-Clean)

구분	모델(연도)	AEPE	핵심 내용
전통적	Horn&Schnuck (1981)	8.739	최초의 Optical Flow 알고리즘으로 한 지점에 대해 주변 픽셀들을 이용하여 계산
	EpicFlow[40] (2015)	4.115	특징점들을 이용하여 두 개의 이미지를 매칭한 후 모서리(Edge)와 함께 비교하여 계산
	DeepFlow[41] (2016)	5.377	피라미드 방식으로 계산한 후 해당 값을 이용하여 에너지 함수(Energy Function)를 최소로 하는 백터를 구하여 추정
	FullFlow[42] (2016)	3.601	픽셀 단위가 아닌 그리드를 이용하여 이미지를 매칭하여 Optical Flow를 계산
	MirrorFlow[43] (2017)	3.316	두 프레임을 이용하여 계산된 값과 역순으로 계산한 값을 비교하여 정확성 향상
딥러닝	FlowNet (2015)	6.081	최초의 Optical Flow를 추정하는 딥러닝 모델
	SpyNet (2016)	6.689	딥러닝을 활용한 공간 피라미드 방식 제안
	FlowNet2.0 (2017)	3.959	FlowNetS 와 FlowNetC를 합쳐서 성능 향상
	MR-Flow[44] (2017)	2.527	경직성 흐름(Rigid-Flow) 방법을 제안하여 독립적으로 움직이는 객체에 대한 추정
	LiteFlowNet (2018)	4.539	FlowNet2.0을 발전시켜서 가볍고 빠른 Optical Flow 추정 가능
	PWC-Net (2018)	4.386	여러 방법들을 하나의 딥러닝 구조로 만듦.
	Mask-FlowNet (2020)	2.521	Occulsion Mask 개념을 제안하여 훈련을 용이하게 함
	RAFT (2020)	1.609	반복 기법과 4D Cost Volume을 활용하여 비약적인 어려움 감소
GMA (2021)	1.388	트랜스포머 기반으로 겹친 픽셀에 대한 움직임 추정 문제를 해결	



(그림 7) Optical Flow 시각화 결과

전통적 방식인 EpicFlow는 객체와 배경 사이의 움직임을 분리하여 추정하지 못하였고, FlowNet2.0은 객체와 배경의 움직임을 분리하였지만 정확하게 분리하지 못했다. 반면에 GMA는 이를 정확하게 분리하여 Optical Flow의 추정을 이뤄내었다.

6. 결 론

본 논문에선 Optical Flow의 최신 추정 방법을 중점적으로 다루고 이를 전통적인 추정 방법과 비교를 하여 두 방법론의 차이를 분석하였다. 또한,

Optical Flow의 활용 사례를 통해 다양한 분야에서 Optical Flow 추정 방식이 다양한 방식으로 활용되는 것을 살펴보았다.

최근에 딥러닝 기반의 Optical Flow 추정이 이뤄지면서 더욱 정확한 추정을 이뤄낼 수 있다. 이러한 정확한 추정을 기반으로 다양한 분야에서 다양한 방법으로 Optical Flow 추정을 통해 활용될 것으로 기대된다. 특히, 자율주행과 지능형 CCTV 시장이 발전하면서 움직임 추정 등의 연구에 많은 발전을 이룰 것이다.

그러나 정확도의 비약적인 향상은 지도 학습 기반의 알고리즘이 주를 이루었고 비지도 학습의 알고리즘은 큰 향상을 이루지 못하였다. 따라서 비교적 정확한 추정이 가능한 비지도 학습 Optical Flow 추정 연구가 지속되어야 한다.

참 고 문 헌

- [1] Lee, Byeong-Yun, "국내외 자율주행자동차 기술개발 동향과 전망." Information and Communications Magazine 33.4 (2016): 10-16.
- [2] 강승준, "시식별추적시스템구축 사업 의의와 성과", 정보통신산업진흥원 이슈리포트 제 20호 pp.4-5, 2020
- [3] Deo, Nachiket, and Mohan M. Trivedi, "Learning and predicting on-road pedestrian behavior around vehicles," 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), IEEE, 2017.
- [4] Baqui, Muhammad, and Rainald Löhner, "Real-time crowd safety and comfort management from CCTV images." Real-Time Image and Video Processing 2017, Vol. 10223, International Society for Optics and Photonics, 2017.

- [5] Fortun, Denis, Patrick Bouthemy, and Charles Kervran, "Optical flow modeling and computation: A survey." Computer Vision and Image Understanding 134 (2015): 1-21.
- [6] Horn, Berthold KP, and Brian G. Schunck, "Determining optical flow." Artificial intelligence 17.1-3 (1981): 185-203.
- [7] Czirik, Andras, et al. "Optical-flow based non-invasive analysis of cardiomyocyte contractility." Scientific reports 7.1 (2017): 1-11.
- [8] Nam, Tae-Jin, Rae-Hong Park, and Jae-Ho Yun, "Optical flow based frame interpolation of ultrasound images." International Conference Image Analysis and Recognition. Springer, Berlin, Heidelberg, 2006.
- [9] Schmoderer, Timothée, et al. "Learning optical flow for fast MRI reconstruction." Inverse Problems (2021).
- [10] 김영민, et al. "딥러닝과 Optical Flow 를 활용한 보행자 사고 방지 모델." 한국정보과학회 학술발표논문집 (2021): 1690-1692.
- [11] Rateke, Thiago, and Aldo von Wangenheim, "Road obstacles positional and dynamic features extraction combining object detection, stereo disparity maps and optical flow data." Machine Vision and Applications 31.7 (2020): 1-11.
- [12] 김지혜, et al. "Optical Flow 기반 CCTV 영상에서의 차량 통행량 및 통행 속도 추정에 관한 연구." 방송공학회논문지 22.4 (2017): 448-461.
- [13] 권언혜, 노승중, and 전문구, "옵티컬 플로우 기반 장면 모델링을 통한 교통 영상 내의 이상 상황 인식 시스템." 한국정보처리학회 학술대회논문집 19.2 (2012): 488-491.
- [14] 백종환, and 김상훈, "드론과 지상로봇 간의 협업을 위한 광학흐름 기반 마커 추적방법."

정보처리학회논문지. 소프트웨어 및 데이터 공학 7.3 (2018): 107-112.

- [15] Urieva, Natallia, et al. "Collision Detection and Avoidance using Optical Flow for Multicopter UAVs." 2020 International Conference on Unmanned Aircraft Systems (ICUAS). IEEE, 2020.
- [16] Lucas, Bruce D., and Takeo Kanade. "An iterative image registration technique with an application to stereo vision." 1981.
- [17] Bouguet, Jean-Yves. "Pyramidal implementation of the affine lucas kanade feature tracker description of the algorithm." Intel corporation 5.1-10 (2001): 4.
- [18] Farneback, Gunnar. "Two-frame motion estimation based on polynomial expansion." Scandinavian conference on Image analysis. Springer, Berlin, Heidelberg, 2003.
- [19] Shi, Jianbo. "Good features to track." 1994 Proceedings of IEEE conference on computer vision and pattern recognition. IEEE, 1994.
- [20] Dosovitskiy, Alexey, et al. "FlowNet: Learning optical flow with convolutional networks." Proceedings of the IEEE international conference on computer vision. 2015.
- [21] Baker, Simon, et al. "A database and evaluation methodology for optical flow." International journal of computer vision 92.1 (2011): 1-31.
- [22] Butler, Daniel J., et al. "A naturalistic open source movie for optical flow evaluation." European conference on computer vision. Springer, Berlin, Heidelberg, 2012.
- [23] Geiger, Andreas, et al. "Vision meets robotics: The kitti dataset." The International Journal of Robotics Research 32.11 (2013): 1231-1237.
- [24] Aubry, Mathieu, et al. "Seeing 3d chairs: exemplar part-based 2d-3d alignment using a large dataset of cad models." Proceedings of the IEEE conference on computer vision and pattern recognition. 2014
- [25] Mayer, Nikolaus, et al. "A large dataset to train convolutional networks for disparity, optical flow, and scene flow estimation." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [26] Richter, Stephan R., Zeeshan Hayder, and Vladlen Koltun. "Playing for benchmarks." Proceedings of the IEEE International Conference on Computer Vision. 2017.
- [27] Ilg, Eddy, et al. "FlowNet 2.0: Evolution of optical flow estimation with deep networks." Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.
- [28] Hui, Tak-Wai, Xiaou Tang, and Chen Change Loy. "LiteflowNet: A lightweight convolutional neural network for optical flow estimation." Proceedings of the IEEE conference on computer vision and pattern recognition. 2018.
- [29] Sun, Deqing, et al. "Pwc-net: Cnns for optical flow using pyramid, warping, and cost volume." Proceedings of the IEEE conference on computer vision and pattern recognition. 2018.
- [30] Ranjan, Anurag, and Michael J. Black. "Optical flow estimation using a spatial pyramid network." Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.
- [31] Brox, Thomas, et al. "High accuracy optical flow estimation based on a theory for

- warping.” European conference on computer vision. Springer, Berlin, Heidelberg, 2004.
- [32] Hu, Yinlin, Rui Song, and Yunsong Li. “Efficient coarse-to-fine patchmatch for large displacement optical flow.” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [33] Teed, Zachary, and Jia Deng. “Raft: Recurrent all-pairs field transforms for optical flow.” European conference on computer vision. Springer, Cham, 2020.
- [34] Chung, Junyoung, et al. “Empirical evaluation of gated recurrent neural networks on sequence modeling.” arXiv preprint arXiv:1412.3555 (2014).
- [35] Ash, Jordan T., and Ryan P. Adams. “On warm-starting neural network training.” arXiv preprint arXiv:1910.08475 (2019).
- [36] Jiang, Shihao, et al. “Learning to Estimate Hidden Motions with Global Motion Aggregation.” arXiv preprint arXiv:2104.02409 (2021).
- [37] Sudheendra Vijayanarasimhan, Susanna Ricco, Cordelia Schmid, Rahul Sukthankar, and Katerina Fragkiadaki. Sfm-net: Learning of structure and motion from video. arXiv preprint arXiv:1704.07804, 2017.
- [38] Zhao, Shengyu, et al. “Maskflownet: Asymmetric feature matching with learnable occlusion mask.” Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020.
- [39] Vaswani, Ashish, et al. “Attention is all you need.” Advances in neural information processing systems, 2017.
- [40] Revaud, Jerome, et al. “Epicflow: Edge-preserving interpolation of correspondences for optical flow.” Proceedings of the IEEE conference on computer vision and pattern recognition, 2015.
- [41] Revaud, Jerome, et al. “Deepmatching: Hierarchical deformable dense matching.” International Journal of Computer Vision 120.3 (2016): 300-323.
- [42] Royer, Loic A., et al. “Convexity shape constraints for image segmentation.” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [43] Tekin, Bugra, et al. “Learning to fuse 2d and 3d image cues for monocular body pose estimation.” Proceedings of the IEEE International Conference on Computer Vision, 2017.
- [44] Wulff, Jonas, Laura Sevilla-Lara, and Michael J. Black. “Optical flow in mostly rigid scenes.” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.

저 자 약 력



김 영 민

이메일 : winston1214@naver.com

- 2020년 차세대융합기술연구원 컴퓨터비전 및 인공지능 연구실 연구원
- 2016년~현재 인천대학교 경제학과/컴퓨터공학부 학사과정
- 관심 분야 : Image Generation, Object Detection, Computer Vision



안 현 옥

.....
이메일 : hyeonukahn@korea.ac.kr

- 2016년~현재 고려대학교 전기전자공학부 학사과정
- 관심분야 : Deep Learning, Computer Vision, Bigdata



김 진 평

.....
이메일 : jpkim@snu.ac.kr

- 2006년 성균관대학교 전자전기컴퓨터공학과 (석사)
- 2014년 성균관대학교 전자전기컴퓨터공학과 (Ph.D., 박사)
- 2016년~2018 한국철도기술연구원 선임연구원
- 2018년~2019 한국도로공사 도로교통연구원 책임연구원
- 2019년~현재 차세대융합기술연구원 선임연구원
- 관심분야 : Artificial Intelligence & Computer Vision