

Dense Optical Flow 기술의 실시간 시스템 적용을 위한 성능 비교 및 분석

*김병준 서창욱 서용덕

서강대학교

*atbem@sogang.ac.kr, mightylg9094@gmail.com, yndk@sogang.ac.kr

Comparison and Analysis of Dense Optical Flow Algorithm for Realtime System

*Kim, Byungjoon Seo, Changwook Seo, Yongduek

*Sogang University

요약

Optical Flow는 컴퓨터 비전 분야의 많은 응용기술에 사용된다. 객체 탐지, 추적, 연속 영상 보간, 3D Reconstruction과 같은 최근에 활발히 연구되는 여러 분야에서 사용되는 기반 기술이다. 최근 딥러닝을 기반으로 한 다양한 연구가 활발히 진행되어 왔으며 높은 정확도를 보이고 있다. 이런 분야들은 많은 경우에 실시간 시스템에 적용되어 이미지로부터 정보를 연산한다.

본 논문은 MaskFlowNet, SelfFlow, LiteFlowNet2 등과 같은 높은 정확도를 가진 신경망 네트워크로 추정된 Optical Flow를 살펴본다. 각 신경망 네트워크로 얻어진 정확도를 비교하고 디스플레이 기술과 이미지 센서 기술의 발전으로 사용 수요가 많아진 고화질의 이미지를 실시간으로 처리하는 경우, 적용 가능한 Optical Flow의 성능을 분석하였다.

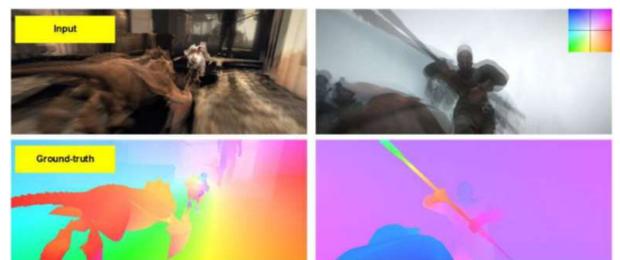
1. 서론

딥러닝을 기반으로 컴퓨터 비전 분야의 연구가 활발히 진행되고 있다. 그리고 디스플레이 기술, 이미지 획득 기술도 빠르게 발전하였다. 이 기술들로 인해 두가지 큰 변화가 생겼다. 첫째는 일상에서 고화질의 데이터들을 사용하게 되었다. HD를 넘어 FHD, UHD 화질의 이미지 데이터를 사용하는 경우가 많아졌으며 보다 정밀한 연산과 대량 연산의 필요가 커졌다. 그리고 두 번째는 이런 고화질 데이터들의 실시간 연산의 필요성이 대두되었다. 도로 주행, 물체 추적, 객체 인식 등 컴퓨터 비전 분야의 다양한 시스템에 실시간 연산의 수요가 발생하였으며 상용화를 위해 연구가 활발히 진행된다.

Optical Flow 추정은 연속된 프레임 간에 동일한 특징점의 변화량을 추정한다. 획득된 정보는 컴퓨터 비전 분야의 응용기술에 적용되어 성능 개선이 기여한다. 예를 들어 자율 주행 시스템에서 도로 정보, 객체 정보를 인식하고 감지 시스템에서 객체를 인식, 추적하는데 기반 정보로 사용된다. 비디오 영역에서 프레임 간 보간 혹은 추가 프레임에 대한 예측에 사용되기도 한다. Optical Flow 추정은 크게 Dense와 Sparse 두 가지로 나뉜다. Dense Optical Flow는 이미지 내부의 모든 픽셀에 대한 흐름을 추정하고 Sparse의 경우 소수의 특징점의 흐름만을 추정한다. 최근에는 신경망 네트워크를 이용한 딥러닝 기술로 다량의 정보를 처리하게 되어 정확도 높은 Dense 정보가 많이 사용된다.

본 논문에서는 딥러닝을 기반으로 하는 Optical Flow 기법에 대해

소개하고 실시간 성능에 대해 분석한다. 분석을 위한 데이터는 MPI Sintel 데이터와 KITTI 2015 데이터를 이용하였다. 해당 데이터들은 Optical Flow의 정보 특성상 Ground Truth Data를 획득하기가 어렵기에 연구 개발을 위해 3D 애니메이션을 이용하여 실제와 가까운 시뮬레이션 데이터를 제공한다. 그리고 앞서 말한 고화질의 이미지 데이터의 실시간 적용 가능성은 FHD 이미지 데이터를 통해 확인하였다.



[그림 1. MPI-Sintel dataset 예시]

2. End Point Error

Optical Flow 추정의 정확도는 Average End Point Error (이하 AEE)를 측정한다. 기본적으로는 아래의 식 (1)과 같다. 영상 내의 전체 픽셀에 대한 수치, 두 프레임 간 공통 픽셀에 대한 수치 두가지로 측정된다.

$$EPE = \sqrt{(\hat{u} - u_{gt})^2 + (\hat{v} - v_{gt})^2} \quad \text{-----} \quad (1)$$

Optical Flow 추정은 신경망 네트워크를 사용하게 되며 정확도 측면에서 큰 성능 향상이 있었으며 표1에서 확인 할 수 있다.

Model	EPE (px. all)	EPE (px.matched)	time (fps)
farneback	9.6	5.4	5ms 200fps
GPC	6.0	2.9	57ms 17fps
PWC-Net	5.0	2.4	28ms 35fps
VCN	4.4	2.2	180ms 5fps
Selfflow	4.2	2.0	86ms 11fps
LiteFlowNet2	4.6	2.2	45ms 22fps
MaskFlowNet	4.1	2.0	60ms 16fps

[표1. Dense Optical Flow 정확도(AEE), 프레임 간 연산시간]

GPC를 비롯해 MaskFlowNet까지 신경망 네트워크를 사용한 기법이 기존의 Dense Optical Flow 추정 기법에 비해 높은 정확도를 확인할 수 있다.

3. 프레임 간 연산속도

프레임 간 연산 속도는 해당 Optical Flow 추정 기술의 실시간 시스템 적합성을 확인할 수 있다. 연속된 두 프레임에서의 추정 연산 시간을 측정하였다. 적용하는 시스템에 따라서 필요한 연산 속도는 다르겠지만 최소 5fps에서 시스템에 따라 60fps 필요할 수 있다. 딥러닝 기반의 Dense Optical Flow 기법은 정확도 측면에서 큰 성능 향상을 가져왔지만 네트워크 내부의 많은 파라미터로 인해 처리시간이 증가하였다. 연산 시간을 측정된 이미지는 MPI-Sintel 데이터로 1024×436 해상도로 해당 이미지를 이용하여 실시간 시스템을 구현할 때 안정적으로 적용 가능한 기법은 PWC-Net임을 보여준다.

4. 화질 차이로 인한 연산속도

앞선 비교 실험은 Ground Truth가 있는 벤치마크 데이터인 MPI-Sintel 데이터(1024×436)가 사용되었다. 하지만 앞서 언급한 것과 같이 최근 연구에 고화질 이미지 데이터가 많이 사용되고 있다. Dense Optical Flow 추정은 이미지 내의 모든 픽셀에 대한 변화량을 연산하기 때문에 아래의 [표2]와 같이 픽셀 수에 대한 시간 성능을 보였다.

해상도	# of pixel	time(ms)	fps
1024×436 (MPI)	446,464	57	17
1920×1080 (FHD)	2,043,600	259	3
2048×1536 (2K)	3,145,728	383	2

[표2 - GPC의 해상도에 따른 Optical Flow 추정 연산 속도]

단순한 픽셀 수로 인한 연산 병렬처리를 통해 많은 부분 개선되었다. 하지만 대부분의 시스템 내부에는 병렬처리가 불가능한 영역이 존재한다. 즉 암달의 법칙에 따라 개선되는 효율의 한계가 있는데 거기에 픽셀의 수가 가장 크게 영향을 미친다. [표2]에서 알 수 있듯이 저해상도의 이미지인 MPI 데이터는 약한 실시간 시스템에 사용 가능성이 확인되지만 FHD 데이터 이상을 사용하는 실시간 시스템에 적용하기에는 한계가 있다.

5. 결론

Dense Optical Flow 추정 기술은 픽셀 기반으로 연산 복잡도를 가진다. 그렇기에 높은 정확도를 가진 딥러닝 기반의 추정 기술도 고화질 시스템의 사용 방법에 따라 적합하지 않을 수 있음을 확인하였다. 하지만 연산의 병렬화, 하드웨어의 고도화로 인해 점차적으로 고화질 영상에 대한 30~60fps의 시스템에 Optical Flow 기술 적용 가능성이 커지는 것 또한 확인할 수 있었다. 본 논문에서 확인한 Optical Flow 추정 기반 기술이 앞으로 연구 및 개발 될 신경망 네트워크, 병렬처리 하드웨어로 인해 여러 응용기술 분야에 적용 될 것을 확인하였다.

감사의 글

This work was supported by 'The Cross-Ministry Giga KOREA Project' grant funded by the Korea government(MSIT) (No.GK20P0300, Real-time 4D reconstruction of dynamic objects for ultra-realistic service)

6. 참고문헌

- [1] Shenlong Wang, et al. "The Global Patch Collider", CVPR, 2016.
- [2] 김병준, 강현민, 서용덕 "대응점 탐색 알고리즘의 GPU 기반 연산에 대한 성능 분석", KCGS 2018.
- [3] Gengshan Yang, Deva Ramanan, "Volumetric Correspondence Networks for Optical Flow", NIPS 2019.
- [4] Sun, Deqing, et al. "PWC-Net: CNNs for optical flow using pyramid, warping, and cost volume." CVPR 2018.
- [5] Pengpeng Liu, et al. "SelfFlow: Self-Supervised Learning of Optical Flow" CVPR 2019.
- [6] Tak-Wai Hui, et al.. "A Lightweight Optical Flow CNN-Revisiting Data Fidelity and Regularization" TPAMI 2020.
- [7] Shengyu Zhao, et al. "MaskFlowNet: Asymmetric Feature Matching With Learnable Occlusion Mask" CVPR 2020.