

2024 겨울 세미나

Hand Pose Estimation



Sogang University
Vision & Display Systems Lab, Dept. of Electronic Engineering



Presented By
MinSuh Song

Outline


- JoonKyu Park, Yeonguk Oh, et al. “**HandOccNet: Occlusion-Robust 3D Hand Mesh Estimation Network.**” CVPR, 2022
- Qichen Fu, Xingyu Liu, et al. “**Deformer: Dynamic Fusion Transformer for Robust Hand Pose Estimation.**” ICCV, 2023

HandOccNet: Occlusion-Robust 3D Hand Mesh Estimation Network

HandOccNet

- Abstract

- 손이 가려진 부분의 정보를 이용하여 3D hand mesh를 재구성하고자 함
- HandOccNet은 두 개의 Transformer 기반 모델로 구성됨
 - Feature Injecting Transformer (FIT)
 - ↳ 손과 연관 있는 occluded region에 hand information을 주입(inject)
 - Self-enhancing Transformer (SET)
 - ↳ Self-attention을 이용하여 FIT의 결과를 refine
- HO-3D, FPHA Dataset에 대한 mean joint error, F-scores에서 SOTA 달성



<HandOccNet 예시>


HandOccNet

- Introduction

- 기존의 연구들은 spatial attention mechanism을 사용
- Spatial attention map을 생성해서 network가 어디에 focus해야 하는지 알려줌
 - Occluded region의 비중을 낮춰서 human region에 focus할 수 있도록 guide

- Limitations

- 3D hand coordinate를 얻기에 적합하지 않음
 - 손이 occluded된 부분이 많으면, hand region에 대한 정보가 부족
- HandOccNet은 occluded region의 정보를 이용하여 hand region을 보완하고자 함



<HandOccNet의 전체적인 구조>

HandOccNet

- Backbone

- 이미지를 입력 받아 feature map(F) 생성, F 를 이용하여 necessity map(M) 생성

- Necessity map은 이미지에서 어떤 픽셀에 focus해야 하는지 알려주는 spatial importance를 제공

- Primary feature(F_p)


- Primary feature = hand region

- $- F_p = F \otimes M$

- Secondary feature(F_s)

- Secondary feature = occluded region


- $- F_s = F \otimes (1 - M)$



HandOccNet

- FIT

- FIT은 F_p 와 F_s 를 입력 받아, F_p 와 연관이 있다고 판단되는 F_s 에 F_p 의 정보를 inject
 - Occlusion을 발생시키는 object information은 손과 매우 연관이 있을 수 있기에 F_s 는 어디에 F_p 를 inject해야 하는지 알려주는 역할을 함
 - 기존의 연구는 F_p 에만 집중하고, F_s 의 값은 최대한 억제
 - HandOccNet은 부족한 F_p 의 정보를 F_s 를 이용하여 보완



HandOccNet


- FIT
 - Softmax based attention module

$$-C_{soft} = softmax\left(\frac{q_{soft}k_{soft}^T}{\sqrt{d_{k_{soft}}}}\right)$$

;; query q_{soft} 는 F_s 로부터 추출, key k_{soft} 는 F_p 로부터 추출

;; Correlation map C_{soft} 는 각 픽셀에서 q_{soft} 와 k_{soft} 의 연관된 정도를 나타내는 역할

;; C_{soft} 를 이용하여 F_s 의 자리에 inject하기 적합한 F_p 를 찾음



HandOccNet



- FIT

- Softmax based attention module

- Softmax based attention module의 한계점

특정 query pixel과 모든 key들이 연관이 없다고 판단될 때, undesired high correlation score 발생

- Undesired high correlation score



<Undesired high correlation score>

HandOccNet

- FIT


- Sigmoid based attention module

$$-C_{sig} = \text{sigmoid}(\text{pool}\left(\frac{q_{sig}k_{sig}^T}{\sqrt{d_{k_{sig}}}}\right))$$

- SoftMax 함수는 입력 element를 다른 element들과 관계를 고려하여 확률 분포로 정규화

- Sigmoid 함수는 입력 element만을 확률로 정규화

↳ Query와 key의 유사도가 작으면 주위에 상관없이 작은 attention-score를 부여




HandOccNet

- FIT

- Sigmoid based attention module

$$- \mathcal{C} = \mathcal{C}_{soft} \otimes \mathcal{C}_{sig}$$


- Undesired high correlation score 문제 해결



HandOccNet

- SET


- F_{FIT} : correlation map C 에 따라 hand information을 occluded region에 주입한 결과
- SET은 distant information을 바탕으로 self-attention을 통해 F_{FIT} 을 refine
- SoftMax의 역할
 - Self-attention의 query와 key의 유사도를 알려주는 correlation map을 생성하기 위함
- F_{FIT} 은 SET를 통과하면서 F_{SET} 로 refine



HandOccNet

- SET

- Input image 그림(a)로부터 hand information을 담고 있는 Primary feature (F_p) 그림(b) 추출
- 그림(c): FIT을 통해 occluded region에 연관된 F_p 를 inject
- 그림(d): SET을 이용해 FIT의 결과를 self-enhancing
 - 그림(c)의 손가락 끝과 손바닥이 연결된 부분
 - 그림(c)의 손과 연관이 없는 occluded region의 비중 감소



HandOccNet

- Evaluating Hand Pose Estimation Models

- HO-3D와 FPHA dataset를 기준으로 mean joint error, mesh error, F-scores로 성능 측정
 - Mean joint error: 추정된 joint와 실제 joint의 위치 차이의 평균
 - Mesh error in mm: 추정된 hand mesh와 실제 hand mesh의 거리 차이의 평균
 - F-scores: 추정된 hand mesh와 실제 hand mesh 사이의 일치하는 정도
 - : F@5: 5mm의 오차를 허용했을 때, 측정값과 실제 값 사이의 일치하는 정도
 - : F@15: 15mm의 오차를 허용했을 때, 측정값과 실제 값 사이의 일치하는 정도

Methods	Joint	Mesh	F@5	F@15
Pose2Mesh [6]	12.5	12.7	44.1	90.9
Hasson <i>et al.</i> [14]	11.4	11.4	42.8	93.2
I2L-MeshNet [26]	11.2	13.9	40.9	93.2
Hasson <i>et al.</i> [15]	11.1	11.0	46.0	93.0
Hampali <i>et al.</i> [13]	10.7	10.6	50.6	94.2
METRO [21]	10.4	11.1	48.4	94.6
Liu <i>et al.</i> [23]	10.2	9.8	52.9	95.0
HandOccNet (Ours)	9.1	8.8	56.4	96.3


< HO-3D에서 HandOccNet 성능비교표>

Methods	3D joint error
I2L-MeshNet [26]	21.2
Hasson <i>et al.</i> [14]	18.0
Liu <i>et al.</i> [23]	16.0
Hasson <i>et al.</i> [15]	14.9
HandOccNet (Ours)	10.8

< FPHA에서 HandOccNet 성능비교표>

HandOccNet


- Experiment



<기존 모델과 HandOccNet의 정성적 평가>

HandOccNet

- Experiment



<기준 모델과 HandOccNet의 정성적 평가>

Deformer: Dynamic Fusion Transformer for Robust Hand Pose Estimation

Deformer

- Abstract


- Video (sequence of frames)에서 3D hand pose estimation을 수행
- 현재 image frame에서 occlusion이나 blur 현상이 발생하면, 전 후 frame의 hand information을 이용해서 estimation을 수행

- Dynamic Fusion Module

- 다른 시간대의 정보를 이용해서 현재 프레임의 hand pose를 deform

- maxMSE Loss

- 새로운 loss function 제시



<Deformer 예시>

Deformer

- Introduction

- Deformer는 spatial transformer, temporal transformer, dynamic fusion module로 구성

- 영상이 입력되면, CNN을 이용하여 프레임 마다 hand feature를 추출

- Spatial transformer


- ↳ 한 프레임에서 손을 나타내는 픽셀들의 관계를 파악

- Global temporal transformer

- ↳ 각 timestamp 마다 프레임 사이의 관계를 파악


- Dynamic fusion model

- ↳ 전후 프레임의 정보를 이용하여 현재 프레임의 추정된 hand pose를 deform




Deformer

- Spatial transformer
 - 이미지의 전체적인 구조를 파악하면서 hand information에 focus 하기 위해 spatial transformer를 활용
 - Video가 입력되면 CNN을 이용하여 매 순간의 timestamp(t)마다 initial hand feature(\mathcal{F}_t)를 추출
 - \mathcal{F}_t 의 sequence를 입력 받아 enhanced 된 feature \mathcal{F}_t^e 를 생성
↳ \mathcal{F}_t^e 는 hand feature vector들의 non-local interaction에 대한 정보를 포함
 - \mathcal{F}_t^e 로부터 $N_j=21$ joints location prediction $\hat{\mathcal{J}}_t^{2D}$ 를 추출
 - Skip connection의 idea를 활용, decoder에서 cross attention을 통해 \mathcal{F}_t^e 와 $\hat{\mathcal{J}}_t^{2D}$ 를 결합
 - 결과적으로 하나의 image에서 손의 모양을 추정하고 joint를 찾음 (\mathcal{F}_t^+)



< Hand keypoints 21 joints >



Deformer

- Temporal Transformer

- 현재 프레임에서 occlusion이나 blur가 발생하면, 전 후 시점의 프레임을 참고하여 estimation 수행


- Transformer의 self-attention으로 인해 프레임들끼리 시간적 거리와 관계없이 정보를 주고 받을 수 있음

- $\{\mathcal{F}_t^+\}_{t=1}^T$ 를 입력 받아서 새로운 latent vector $\{\mathcal{F}_t^{++}\}_{t=1}^T$ 를 출력

- $\{\mathcal{F}_t^{++}\}_{t=1}^T$ 를 MLP에 전달하여 MANO pose parameter $\hat{\theta}_t$ 를 생성


- $\hat{\theta}_t$ 만을 이용하여 estimation을 수행하면 전체적인 손의 모양의 일관성이 유지되지 않음

∴ Global hand shape query와 $\{\mathcal{F}_t^{++}\}_{t=1}^T$ 를 cross-attention하여 global shape parameter $\hat{\beta}^+$ 를 예측



Deformer

- Dynamic fusion module
 - Temporal transformer의 결과인 $\{\mathcal{F}_t^{++}\}_{t=1}^T$ 만을 사용하면 현재 프레임에 대한 dependency가 강함
 - 전후 프레임의 정보를 단순히 참고하는 것이 아닌, 이를 이용하여 현재 프레임의 추정된 hand pose를 deform
 - $\{\mathcal{F}_t^{++}\}_{t=1}^T$ 에서 추가로 confidence score \hat{c}_t 와 현재 모션으로부터 전후 시점의 hand motion ($\hat{d}\theta_t^{fw}, \hat{d}\theta_t^{bw}$)를 추출
 - Forward motion: $\hat{d}\theta_t^{fw} = \theta_{t+1} - \theta_t$ (다음 시점의 MANO parameter와 현재 값과의 차이)
 - Backward motion: $\hat{d}\theta_t^{bw} = \theta_{t-1} - \theta_t$ (이전 시점의 MANO parameter와 현재 값과의 차이)



<Dynamic Fusion Module>

Deformer


- Dynamic fusion module

- Forward, backward motion을 이용하면 frame j의 hand pose parameter를 frame i가 영향을 주어 변형할 수 있음

$$-\hat{\theta}_{i \rightarrow j} = \begin{cases} \hat{\theta}_i + \sum_{k=j}^{i-1} \hat{d}\theta_k^{bw} & (if\ j < i) \\ \hat{\theta}_i + \sum_{k=i}^{j-1} \hat{d}\theta_k^{fw} & (if\ j > i) \end{cases}$$


- 모든 timestamp t의 변형된 hand pose를 합성하여 최종 hand pose parameter $\hat{\theta}_t^+$ 를 생성함

$$-\hat{\theta}_t^+ = \frac{\sum_{t'=1}^T e^{\hat{c}_{t'}} \hat{\theta}_{t' \rightarrow t}}{\sum_{t'=1}^T e^{\hat{c}_{t'}}}$$




Deformer


- maxMSE Loss
 - 기존의 standard MSE loss는 손의 서로 다른 부분들에 대해서 고르지 않은 에러를 보임
 - MSE loss를 사용한 모델은 손바닥에서 특히 낮은 에러와, 손가락과 같은 섬세하고 복잡한 부분에 대해서는 높은 에러를 보임
 - 본 논문은 새로운 loss function으로 maxMSE를 제안
 - maxMSE loss는 large error를 가진 joint나 vertices에는 large weight를 부여하고, well-predicted parts에는 lower weight를 부여함



<Error에 따라 부여되는 weight 비교>



<Error imbalance issue가 완화된 모습>



Deformer

- Motion Discriminator
 - Temporal Incontinuity
 - 영상을 프레임 단위의 이미지로 나누고, 이를 다시 합쳐서 재생했을 때 매크롭지 못하고 툭툭 끊기는 현상
 - Motion discriminator는 hand mesh sequence를 입력 받아 적합성을 판별
 - Deformer를 generator로 하고 motion discriminator를 이용하여 adversarial training을 진행

maxMSE	Motion Discrimination	All	Occlusion (25%-50%)	Occlusion (50%-75%)	Occlusion (75%-100%)
✗	✗	5.72 (88.6)	6.11 (87.8)	6.14 (87.7)	6.75 (86.5)
✗	✓	5.63 (88.7)	6.00 (88.0)	5.92 (88.2)	6.62 (86.8)
✓	✗	5.43 (89.1)	6.05 (87.8)	6.00 (88.0)	6.59 (86.8)
✓	✓	5.22 (89.6)	5.71 (88.6)	5.70 (88.6)	6.34 (87.3)

<Ablation Study>

Deformer

- Experiment

- HO-3D와 DexYCB dataset를 기준으로 mean per joint position error, F-scores, AUC scores로 성능 측정

- Mean per joint position error (MPJPE): 추정된 joint와 실제 joint의 위치 차이의 평균

- F-scores: 추정된 hand mesh와 실제 hand mesh 사이의 일치하는 정도

- F@5: 5mm의 오차를 허용했을 때, 측정값과 실제 값 사이의 일치하는 정도

- F@15: 15mm의 오차를 허용했을 때, 측정값과 실제 값 사이의 일치하는 정도


- AUC scores: 모델이 성공적으로 결과를 판단하는 정도

Methods	Input	All	Occlusion (25%-50%)	Occlusion (50%-75%)	Occlusion (75%-100%)
A2J [55]	Depth	12.07 (76.0)	12.44 (75.3)	14.74 (70.7)	19.59 (61.5)
[49] + ResNet50	Monocular	7.12 (85.8)	7.65 (84.7)	8.73 (82.6)	11.90 (76.3)
[49] + HRNet32	Monocular	6.83 (86.4)	7.22 (85.6)	8.00 (84.0)	10.65 (78.8)
MeshGraphomer [33]	Monocular	6.41 (87.2)	6.85 (86.3)	7.22 (85.6)	7.76 (84.5)
[36]	Monocular	6.33 (87.4)	6.70 (86.6)	7.17 (85.7)	8.96 (82.1)
[40]	Monocular	5.80 (88.4)	6.22 (87.6)	6.43 (87.2)	7.37 (85.3)
$S^2HAN(V)$ [51]	Sequence	7.27 (85.5)	7.74 (84.5)	7.71 (84.6)	7.87 (84.3)
VIBE [29]	Sequence	6.43 (87.1)	6.72 (86.5)	6.84 (86.4)	7.06 (85.8)
TCMR [10]	Sequence	6.28 (87.5)	6.56 (86.9)	6.58 (86.8)	6.95 (86.1)
Ours	Sequence	5.22 (89.6)	5.71 (88.6)	5.70 (88.6)	6.34 (87.3)

< DexYCB에서 MPJPE (AUC) 비교표 >

Deformer

- Experiment




Methods	Input	Hand Error (\downarrow)		Hand F-score (\uparrow)	
		Joint	Mesh	F@5	F@15
[20]	Monocular	11.1	11.0	46.0	93.0
[17]	Monocular	10.7	10.6	50.6	94.2
[36]	Monocular	10.1	9.7	53.2	95.2
[40]	Monocular	9.1	8.8	56.4	96.3
VIBE [29]	Sequence	9.9	9.5	52.6	95.5
TCMR [10]	Sequence	11.4	10.9	46.3	93.3
TempCLR [61]	Sequence	10.6	10.6	48.1	93.7
Ours	Sequence	9.4	9.1	54.6	96.3

<MPJPE, F-scores 비교표>

Deformer


- Experiment
 - (Top): Semi-Hand-object
 - Single-view method
 - (Middle): Mask R-CNN
 - Video-based method
 - (Bottom): Deformer



<기존 모델들과 Deformer의 정성적 평가>

Deformer


- Experiment



<DexYCB dataset을 이용한 정성적 결과>

Deformer

- Experiment



<HO-3D dataset을 이용한 정성적 결과>

감사합니다