



Лаборатория компьютерной
графики и мультимедиа
ВМК МГУ имени М.В. Ломоносова

Курс «Компьютерное зрение»

«Сегментация изображений»

Антон Конушин и Тимур Мамедов

2025 год




1. Такая разная сегментация
2. Пересегментация
3. Семантическая сегментация
4. Интерактивная
5. Сегментация экземляров
6. Паноптическая сегментация
7. Оценка позы человека

Задача сегментации



Разделение изображения на фрагменты(группы пикселов) по определённому критерию





Извлечение объекта

Выделение конкретного произвольного объекта, указанного пользователем или по другому заданного



Сегментация без учителя




Разделение изображения на регионы, однородные по своим визуальным характеристикам, и отличающихся от соседних регионов





Семантическая сегментация

Попиксельная разметка изображения, где каждая метка соответствует определенному объекту



- Разные пиксели одного объекта существенно отличаются друг от друга по признакам (яркости, цвету, текстуре окрестности)
- Единственное, что у них общее – это «семантика»
- Поэтому задача сегментации объекта тесно связана с задачей распознавания

Instance segmentation



Выделение всех отдельных экземпляров объектов определённого класса. Каждый объект помечен своей меткой.



Panoptic segmentation



(a) image



(b) semantic segmentation



(c) instance segmentation




(d) panoptic segmentation

Объединение задача semantic и instance segmentation в единую модель

Source: <https://arxiv.org/pdf/1801.00868.pdf>



Оценка позы человека



Photograph taken from Pexels

Какая связь с сегментацией?



1. Такая разная сегментация
2. Визуальная сегментация
3. Семантическая сегментация
4. Интерактивная
5. Сегментация экземпляров
6. Паноптическая сегментация
7. Оценка позы человека


Требования к сегментации?



Каким условиям должны удовлетворять сегменты?

- Границы сегментов должны соответствовать границам объектов
- Сегмент должен целиком содержаться внутри объекта
- Небольшие объекты не должны быть частью сегмента, а описываться своим сегментом
- Сегмент должен быть однородным по визуальным характеристикам
- Сегменты должны быть достаточно большими, чтобы быть «информационными»
- Компактные, примерно одного размера
- Равномерно распределенные по изображению
- Алгоритм должен работать быстро

Суперпиксели




- Сегменты, «удовлетворяющие» вышеуказанным требованиям называют «суперпиксели»
- «Суперпиксельная сегментация»
- Ещё называют «пересегментацией» (oversegmentation)

Пересегментация через кластеризацию




- Представим множество пикселов как выборку (множество вектор-признаков)
- Применим какой-нибудь метод кластеризации к данным в пространстве признаков
- Каждый кластер будет соответствовать одному сегменту
- Как обеспечить «локальность» кластеров в изображении?
 - (x,y) можно включить в вектор-признак
 - Жесткие ограничения на расстояния между пикселями

Simple linear iterative clustering (SLIC)




(a) standard k -means searches
the entire image



(b) SLIC searches
a limited region

- Зачем сопоставлять пиксель со *всеми* остальными?
- Будем сравнивать с «центром кластера» только пиксели, которые *могут* принадлежать этому сегменту (на расстоянии $< s$)
- Инициализируем кластеры по сетке на расстоянии s

Алгоритм SLIC



- Инициализируем центры кластеров C_k по сетке с шагом S
- Инициализируем в каждом пикселе метку $L(i) = -1$ и расстояние $D(i)$ до ближайшего кластера $-\infty$
- Проходим по кластерам C_k
 - Для каждого пикселя в области $2S \times 2S$ считаем расстояние до C_k
 - Расстояние считаем в CIE LAB + (x,y)
 - Если расстояние меньше $D(i)$, тогда ставим метку $L(i) = k$, и записываем в $D(i)$ новое значение
- Повторяем до тех пор, пока суммарное изменение кластеров не будет меньше порога



Примеры работы



$$\text{Сложность} - \left(\frac{n}{S}\right)^2 S^2 t = n^2 t = Nt$$


Визуальное сравнение



Efficient Graph-Based



TurboPixel



QuickShift



SLIC



1. Такая разная сегментация
2. Пересегментация
3. Семантическая сегментация
4. Интерактивная
5. Сегментация экземляров
6. Паноптическая сегментация
7. Оценка позы человека

Семантическая сегментация




Метрики качества



Source: <https://arxiv.org/abs/1611.09326>

- Intersection over Union (IoU) – по классам



$$\text{segmentation accuracy} = \frac{\text{true positives}}{\text{true positives} + \text{false positives} + \text{false negatives}}$$

- mIoU (mean IoU) – средняя IoU по всем классам
- Per-class pixel accuracy:

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$


Cityscapes как пример датасета (CVPR 2016)



- Изображения с камеры автомобиля
- 30 классов объектов
- 5000 хорошо размеченных и 20000 грубо размеченных изображений
- 1.5 часа на разметку 1 изображения

<https://www.cityscapes-dataset.com/>

Сегментация по свёрточным признакам




- Сегментацию можно представить как попиксельную классификацию
- Применим свёрточную архитектуру для классификации к изображению, пр. VGG16
- Получим матрицу признаков с разрешением в 32 раз меньше
- Для каждого пикселя признаков применим классификатор для оценки классов
 - Примерно как RPN в Faster R-CNN
- Получим карту разметки низкого разрешения
- Нужно повысить разрешение до исходного!


DeepLab





Воспользуемся билинейной интерполяцией и Dense CRF для повышения разрешения



Результаты




Transposed convolution



Можем увеличить разрешение картинки, расставив пиксели редко, и затем интерполируя значения в промежутках с помощью свёртки

Fully convolutional networks



- CNN признаки низкого разрешения на последнем уровне (32x уменьшение)
- Несколько этапов повышения разрешения через “deconvolutional filters”
- Выход уровня повышения разрешения складывается с признаками соответствующего уровня кодирования

Max Unpooling



Max Pooling

Remember which element was max!

1	2	6	3
3	5	2	1
1	2	2	1
7	3	4	8

Input: 4 x 4

Output: 2 x 2



Max Unpooling

Use positions from pooling layer

1	2
3	4



Input: 2 x 2

0	0	2	0
0	1	0	0
0	0	0	0
3	0	0	4

Output: 4 x 4


- Сохраняем индексы каждого max-pooling слоя
- Про повышении разрешения делаем так:
 - Копируем значения из выхода max-pooling слоя с учётом запомненный индексов
 - Применяем обученные свёртки для сглаживания

Encoder-Decoder with Max Unpooling




- Меняем схему «повышения разрешения»
- Сохраняем индексы каждого max-pooling слоя
- Про повышении разрешения делаем так:
 - Копируем значения из выхода max-pooling слоя с учётом запомненный индексов
 - Применяем обученные свёртки для сглаживания
- Делаем в несколько этапов до исходного разрешения

Deconvolutional network




- По всему изображению строим вектор признаков 1×1
- Используя сохранённые max-pooling индексы повышаем разрешение до исходного, предсказывая карту разметки

U-Net




Добавим обходные пути (skip connections)

Hourglass & Stacked Hourglass




Навесим на обходные пути
дополнительные блоки для обработки
информации



Объединим модули
в цепочку (каскад)


Atrous Convolution




$$y[i] = \sum_k x[i + r \cdot k]w[k]$$

Мы применяем 3x3 свёртку, но отсёты берём с шагом r

Going Deeper with atrous convolutions



(a) Going deeper without atrous convolution.




(b) Going deeper with atrous convolution. Atrous convolution with $rate > 1$ is applied after block3 when $output_stride = 16$.

ASPP



- Ключевой элемент DeepLab, начиная с v2 (сейчас версия 3+)



- Строим «пирамиду», собирая признаки с разных масштабов.




Fig. 3. Illustrating how the fusion module aggregates the information for high, medium and low resolutions from left to right, respectively. Right legend: strided 3×3 = stride-2 3×3 convolution, up samp. 1×1 = bilinear upsampling followed by a 1×1 convolution.

Использование HRNet





Figure 3. (a) The high-resolution representation proposed in [91] (HRNetV1); (b) Concatenating the (upsampled) representations that are from all the resolutions for semantic segmentation and facial landmark detection (HRNetV2); (c) A feature pyramid formed over (b) for object detection (HRNetV2p). The four-resolution representations at the bottom in each sub-figure are outputted from the network in Figure 1, and the gray box indicates how the output representation is obtained from the input four-resolution representations.

SegFormer



Efficient SA:

$$SA = \text{softmax}(qk^T / \sqrt{D_h})v$$

$$k = \text{Reshape}(\frac{N}{R}, C \cdot R)(k)$$

$$k = \text{Linear}(C \cdot R, C)(k)$$

Mix-FFN:

$$MLP(\text{Conv}_{3 \times 3}(MLP(x))) + x$$

- Не используем positional encoding
- Комбинируем self-attention и свёртки 3×3 для учёта пространственной информации

SegFormer



Резюме сегментационных моделей




- Основной подход для построения сегментационных сетей – Encoder-Decoder
- В качестве Encoder мы берём любую классификационную сеть
- Decoder состоит из блоков, между которыми повышается разрешение
- Есть несколько способов повышения разрешения
- Обходные пути позволяют учитывать признаки высокого разрешения из Encoder
- Трансформерные архитектуры обеспечивают контекст за счёт self-attention, и мы можем декодер упростить




1. Такая разная сегментация
2. Пересегментация
3. Семантическая сегментация
4. Интерактивная сегментация
5. Сегментация экземляров
6. Паноптическая сегментация
7. Оценка позы человека




Интерактивная сегментация




Пользовательский ввод



Клики



Bounding box



Мазки



Контур

Интерактивный режим!

Датасеты и метрики




Berkeley — 50 images

GrabCut — 100 images

DAVIS — 345 images

SBD — 2857 images, 6671
masks



- NoC@0.9 – Сколько кликов нужно сделать, чтобы добиться уровня IoU 0.9
- Обычно ограничивают максимум 20

Deep GrabCut






Figure 2: The framework of our segmentation model. The rectangle is indicated in green in the “Image” and “Distance map”. The symbol \oplus denotes the concatenation operation.

Насколько это интерактивный метод?






- Кодирование кликов
- Смешение с признаками изображения
- Итеративное обучение
- Использование маски с прошлого шага
- Использование современных датасетов (COCO+LVIS) для обучения


Zoom-In



Segment Anything Model (SAM)



SegmentAnything







- Используем ViT для кодирования изображения
- “Amortized inference” – признаки изображения считаем через encoder один раз, а интерактивную информацию и маску подмешиваем только перед легковесным декодером



1. Такая разная сегментация
2. Пересегментация
3. Семантическая сегментация
4. Интерактивная
5. Сегментация экземляров
6. Паноптическая сегментация
7. Оценка позы человека

Instance Segmentation



Mask R-CNN для Instance Segmentation




Figure 1. The **Mask R-CNN** framework for instance segmentation.



Результаты




Figure 4. More results of **Mask R-CNN** on COCO test images, using ResNet-101-FPN and running at 5 fps, with 35.7 mask AP (Table 1).




1. Такая разная сегментация
2. Пересегментация
3. Семантическая сегментация
4. Интерактивная
5. Сегментация экземляров
6. Паноптическая сегментация
7. Оценка позы человека

Panoptic Feature Pyramid Networks




(a) Feature Pyramid Network




(b) Instance Segmentation Branch

(c) Semantic Segmentation Branch




Возьмём идею Mask R-CNN и дополним её веткой семантической сегментации по тем же признакам

DETR




Дополним список классов `stuff`, и будем предсказывать `bbox` этих классов



Добавим голову для предсказания масок по `bbox` предсказаниям `stuff` классов

Mask2Former




- Развитие Encoder-Decoder архитектуры + Feature Pyramid
- Backbone + Pixel Decoder + Transformer Decoder
- Можем использовать ResNet или SwinTransformer как backbone
- Простая модель FPN для генерации признаков высокого разрешения для Pixel Decoder
- Добавим голову для предсказания масок по bbox предсказаниям stuff классов
- Masked Attention учитывает только признаки из маски

OneFormer




3 architectures, 3 models & 3 datasets




(a) Specialized Architectures, Models & Datasets

1 architecture, 3 models & 3 datasets



(b) Panoptic Architecture BUT Specialized Models & Datasets

1 architecture, 1 model & 1 dataset






(c) Universal Architecture, Model and Dataset

OneFormer






(a) Multi-Scale Feature Modeling



Panoptic GT

Instance GT

Semantic GT





(b) Unified Task-Conditioned Query Formulation

(c) Task-Dynamic Mask and Class Prediction Formation

OneFormer



Panoptic GT





[a photo with a car, a photo with a person, a photo with a person, a photo with a rider, a photo with a bicycle, a photo with a road, a photo with a sidewalk, a photo with a pole, a photo with a building, a photo with a vegetation, a photo with a traffic sign]

Panoptic List

Panoptic List + [a panoptic photo, a panoptic photo, ...]

Instance GT





[a photo with a car, a photo with a person, a photo with a person, a photo with a rider, a photo with a bicycle]

Instance List

Instance List + [an instance photo, an instance photo, ...]

Semantic GT



[a photo with a car, a photo with a person, a photo with a rider, a photo with a traffic sign, a photo with a bicycle, a photo with a road, a photo with a sidewalk, a photo with a pole, a photo with a building, a photo with a vegetation]

Semantic List

Semantic List + [a semantic photo, a semantic photo, ...]

(a) Task based GT Label

(b) Extract number of binary masks for each class

(c) Form a list with text for each mask's class type

(d) Pad extracted Text to obtain a list of length N_{text}

OneFormer




Figure 4. **Text Mapper.** We tokenize and then encode the input text list (T_{pad}) using a 6-layer transformer text encoder [49, 57] to obtain a set of N_{text} embeddings. We concatenate a set of N_{ctx} learnable embeddings to the encoded representations to obtain the final N text queries (Q_{text}). The N text queries stand for a text-based representation of the objects present in an image.

$$\mathcal{L}_{\mathbf{Q} \rightarrow \mathbf{Q}_{\text{text}}} = -\frac{1}{B} \sum_{i=1}^B \log \frac{\exp(q_i^{\text{obj}} \odot q_i^{\text{txt}} / \tau)}{\sum_{j=1}^B \exp(q_i^{\text{obj}} \odot q_j^{\text{txt}} / \tau)},$$
$$\mathcal{L}_{\mathbf{Q}_{\text{text}} \rightarrow \mathbf{Q}} = -\frac{1}{B} \sum_{i=1}^B \log \frac{\exp(q_i^{\text{txt}} \odot q_i^{\text{obj}} / \tau)}{\sum_{j=1}^B \exp(q_i^{\text{txt}} \odot q_j^{\text{obj}} / \tau)}$$
$$\mathcal{L}_{\mathbf{Q} \leftrightarrow \mathbf{Q}_{\text{text}}} = \mathcal{L}_{\mathbf{Q} \rightarrow \mathbf{Q}_{\text{text}}} + \mathcal{L}_{\mathbf{Q}_{\text{text}} \rightarrow \mathbf{Q}}$$

OneFormer



Method	Backbone	#Params	#FLOPs	#Queries	Crop Size	Iters	PQ	AP	mIoU (s.s.)	mIoU (m.s.)
Individual Training										
CMT-DeepLab [‡] [59]	MaX-S [†] [50]	—	—	—	1025×2049	60k	64.6	—	81.4	—
Axial-DeepLab-L [‡] [51]	Axial ResNet-L [†] [51]	45M	687G	—	1025×2049	60k	63.9	35.8	81.0	81.5
Axial-DeepLab-XL [‡] [51]	Axial ResNet-XL [†] [51]	173M	2447G	—	1025×2049	60k	64.4	36.7	80.6	81.1
Panoptic-DeepLab [‡] [11]	SWideRNet [†] [8]	536M	10365G	—	1025×2049	60k	66.4	40.1	82.2	82.9
Mask2Former-Panoptic [12]	Swin-L [†] [38]	216M	514G	200	512×1024	90k	66.6	43.6	82.9	—
Mask2Former-Instance [12]	Swin-L [†] [38]	216M	507G	200	512×1024	90k	—	43.7	—	—
Mask2Former-Semantic [12]	Swin-L [†] [38]	215M	494G	100	512×1024	90k	—	—	83.3	84.3
kMaX-DeepLab [‡] [60]	ConvNeXt-L [†] [39]	232M	1673G	256	1025×2049	60k	68.4	44.0	83.5	—
Joint Training										
OneFormer	Swin-L [†] [38]	219M	543G	250	512×1024	90k	67.2	45.6	83.0	84.4
OneFormer	ConvNeXt-L [†] [39]	220M	497G	250	512×1024	90k	68.5	46.5	83.0	84.0
OneFormer	ConvNeXt-XL [†] [39]	372M	775G	250	512×1024	90k	68.4	46.7	83.6	84.6
OneFormer	DiNAT-L [†] [21]	223M	450G	250	512×1024	90k	67.6	45.6	83.1	84.0

Table 2. **SOTA Comparison on Cityscapes val set.** [†]: backbones pretrained on ImageNet-22K; [‡]: trained with batch size 32, *: hidden dimension 1024. OneFormer outperforms the individually trained Mask2Former [12] models. Mask2Former’s performance with 250 queries is not listed, as its performance degrades with 250 queries. We compute FLOPs using the corresponding crop size.


План лекции



1. Такая разная сегментация
2. Визуальная сегментация
3. Семантическая сегментация
4. Интерактивная сегментация
5. Сегментация экземляров
6. Паноптическая сегментация
7. Оценка позы человека



Оценка позы человека



Photograph taken from Pexels

Какая связь с сегментацией?



Метрики

Percentage of Correct Parts - PCP: A limb is considered detected (a correct part) if the distance between the two predicted joint locations and the true limb joint locations is less than half of the limb length (Commonly denoted as PCP@0.5).


- It measures the detection rate of limbs. The con is that it penalizes shorter limbs more since shorter limbs have smaller thresholds.

Percentage of Correct Key-points - PCK: A detected joint is considered *correct* if the distance between the predicted and the true joint is within a certain threshold. The threshold can either be:

- PCKh@0.5 is when the threshold = 50% of the head bone link
- PCK@0.2 == Distance between predicted and true joint $< 0.2 * \text{torso diameter}$



Прямая регрессия



Поза человека через сегментацию




Fig. 2. Example output produced by our network. On the left we see the final pose estimate provided by the max activations across each heatmap. On the right we show sample heatmaps. (From left to right: neck, left elbow, left wrist, right knee, right ankle)



Простой baseline

- ResNet + deconvolution



ECCV2018 paper "Simple Baselines for Human Pose Estimation and Tracking» (<https://arxiv.org/abs/1804.06208>)

<https://github.com/Microsoft/human-pose-estimation.pytorch>


Оценка качества



Table 4. Comparisons on COCO test-dev dataset. **Top:** methods in the literature, trained only on COCO training dataset. **Middle:** results submitted to COCO test-dev leaderboard [9], which have either extra training data (*) or models ensamled (+). **Bottom:** our single model results, trained only on COCO training dataset.

Method	Backbone	Input Size	AP	AP ₅₀	AP ₇₅	AP _m	AP _l	AR
CMU-Pose [5]	-	-	61.8	84.9	67.5	57.1	68.2	66.5
Mask-RCNN [12]	ResNet-50-FPN	-	63.1	87.3	68.7	57.8	71.4	-
G-RMI [24]	ResNet-101	353 × 257	64.9	85.5	71.3	62.3	70.0	69.7
CPN [6]	ResNet-Inception	384 × 288	72.1	91.4	80.0	68.7	77.2	78.5
FAIR* [9]	ResNeXt-101-FPN	-	69.2	90.4	77.0	64.9	76.3	75.2
G-RMI* [9]	ResNet-152	353 × 257	71.0	87.9	77.7	69.0	75.2	75.8
oks* [9]	-	-	72.0	90.3	79.7	67.6	78.4	77.1
bangbangren* ⁺ [9]	ResNet-101	-	72.8	89.4	79.6	68.6	80.0	78.7
CPN ⁺ [6,9]	ResNet-Inception	384 × 288	73.0	91.7	80.9	69.5	78.1	79.0
Ours	ResNet-152	384 × 288	73.7	91.9	81.1	70.3	80.0	79.0

OpenPose



(a) Input Image


(c) Part Affinity Fields

(d) Bipartite Matching


(e) Parsing Results

P Pooling
C Convolution

Input Image
 $h \times w \times 3$



VGG - 19





Примеры работы



Резюме лекции



- Множество разных задач сегментации
 - Извлечение объектов
 - Пересегментация / суперпиксели
 - Семантическая сегментация
 - Instance segmentation
 - Паноптическая сегментация
 - Поза человека через сегментацию
- Текущее развитие
 - Нейросетевые модели = построение признаков + предсказание попиксельное
 - Encoder-decoder vs признаки высокого разрешения
 - Сегментационная голова как дополнение к другим моделям
 - Трансформерные модели