



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

*Курс «Компьютерное зрение»*

## **«Основы анализа видео»**

Антон Конушин и Мамедов Тимур


2025 год



1. Введение
2. Оптический поток и его оценка
3. Распознавание событий в видео
4. Отслеживание одного объекта
5. Отслеживание множества объектов

# Виды видео

---



**Видеопоток** – упорядоченная последовательность изображений, полученных с одной камеры через небольшие промежутки времени/ Видеопоток подразумевает обработку на лету.

**Видеопоследовательность** же конечна, можно обрабатывать целиком.

- Пользовательское видео – от 3-5 кадров/сек до 30-50 кадров/сек
- Разрешение – от 320x240 до 1920\*1080 (HD) (сейчас ещё 4K)
- В градациях серого (одноканальное) или цветное (3х канальное)
- Поток данных – 2Мб (один канал HD) x 3 (RGB) x 30 кадр/с = 180 Мб/с
  - Сравнимо с пропускной способностью 1Gb Ethernet сети

# Сценарии съёмки




- Ракурс, вид наблюдаемых объектов и т.д.
- Ракурсы съёмки могут быть крайне различны
- Работающие системы удается создать, «заточившись» на определённый сценарий съёмки



1. Введение в обработку и анализ видео
2. Оптический поток и его оценка
3. Распознавание событий в видео
4. Отслеживание одного объекта
5. Отслеживание множества объектов



# В чём главное отличие видео от изображений?

---



- Движение – главное отличие видео от изображений
- Движение само по себе является мощной визуальной подсказкой
- Суть многих действий именно в динамике


# Описание движения



- Точки наблюдаемой сцены движутся относительно камеры / изображения
- Векторное поле движения 2D проекций на изображение 3D точек объектов сцены называется *полем движения* (*motion field*)
- Нужно это движение как-то формализовать, описывать и измерять


# Оптический поток

---



- Движение точек объектов по видео увидеть можно далеко не всегда
- E.g. Серый матовый шар, освещается с одной стороны и вращается вокруг своей оси
- Optical flow (оптический поток) – векторное поле видимого (apparent) движения пикселей между кадрами
- Вычисление оптического потока – одна из базовых задач анализа видео


# Формализация задачи




- Optical flow – векторное поле видимого движения пикселей между кадрами  $(u_{ij}, v_{ij})$
- Это задача **плотного** сопоставления
- Для каждой точки  $(x_{ij}, y_{ij})$  на первом кадре нужно найти точку на втором кадре  $(x_{ij} + u_{ij}, y_{ij} + v_{ij})$



# Визуализация



Вектора движения для  
отдельных точек или всего  
изображения




Цветовое кодирование вектора  
движения. Каждому направлению и  
амплитуде свой цвет и яркость

Оптический поток - векторное поле  $(u_{ij}, v_{ij})$  видимого (наблюдаемого) движения пикселей между кадрами

# Middlebury optical flow dataset



Как получить эталонные данные?




Покадровая съёмка в обычном и флуоресцентном свете



Синтетические  
данные


Source: S.Baker et. al. A Database and Evaluation Methodology for Optical Flow, IJCV, 2011



- 3D сканирование
- Отдельно фон и движущиеся объекты
- Вписывание 3D моделей объектов в движущиеся объекты


[http://www.cvlibs.net/datasets/kitti/eval\\_flow.php](http://www.cvlibs.net/datasets/kitti/eval_flow.php)

# MPI Sintel



1064 training and 564 test frames, 1024 x 436 разрешение

# Spring




6000 FullHD кадров

4K ground truth




Прямолинейное применение свёрточных нейросетей к вычислению оптического потока



# FlowNet



FlowNetSimple



- Объединяем 2 кадра в би канальное изображение
- Применяем нейросеть
- Можно сделать сложнее, объединив признаки с 2x картинок с помощью специального слоя сравнения патчей




# Flying chairs



	Frame pairs	Frames with ground truth	Ground truth density per frame
<b>Middlebury</b>	72	8	100%
<b>KITTI</b>	194	194	~50%
<b>Sintel</b>	1041	1041	100%
<b>Flying Chairs</b>	22872	22872	100%

- Не хватает данных для обучения
- Поэтому синтетический набор из летающих стульев


# PWC-Net (Pyramid, Warping, Cost volume)




- Реализуем классический подход, но через нейросетевые признаки и нейросетевой вывод
- Вычисляем “Cost Volume” через корреляцию пикселей со сдвигом не более  $d$
- Размер CV =  $d^2 * Width * Height$
-



# Некоторые детали




OF Estimator берёт на вход Cost Volume, Optical Flow, и Features




- Сеть Context делает пост-обработку
- На вход признаки и OF

# RAFT




- Поддерживаем оценку OF в высоком разрешении без пирамиды
- Используем рекуррентный элемент для уточнения OF

# FlowFormer



- Сжимаем cost volume в токены ( $H^2 \times W^2 \rightarrow H \times W \times K \times D$ )
- 2-х стадийное внимание: вначале для токенов внутри cost map и затем между cost maps
- Декодер с cost queries

# FlowFormer



# SAMFlow





Figure 2: The overview of our SAMFlow, which utilizes the frozen SAM image encoder to boost the object perception of the optical flow model FlowFormer. We design two modules for in-depth utilizing SAM, including: (a) the CFM, which fuses SAM features with FlowFormer encoder, and (b) the CAM, which adapts the features with the Learned Task-Specific Embedding.

Всё становится лучше, если добавить признаки от фундаментальной модели



1. Введение в обработку и анализ видео
2. Оптический поток и его оценка
3. Распознавание событий в видео
4. Отслеживание одного объекта
5. Отслеживание множества объектов

# Action recognition

---



Human actions are the main content of movies, TV news and shows, home video and video surveillance



- Smart surveillance
  - *Abnormal situation detection*
- Video archive indexing and retrieval
  - *Search for a scene with Putin and Obama handshake*
- Content navigation
  - *Rewind to the next goal in the soccer match*

# Human action

---



The most basic actions are simple body movements like walking or running or clapping hands.



Walking



Jogging



Running



Boxing



Waving



Clapping

# Actions

---



Short meaningful movements



Answer phone



Handshake

# Actions and events

---



A set of small actions with a specific common goal can still be called an “action” but we can also call them “events”



Making sandwich



Doing homework

# Events

---



An event can include a lot of different actions of different people



Birthday party



Parade

# Tasks



Action or event classification: assign a label of action or event to a video



Making sandwich: present  
Feeding animal: not present  
...

Action localization: search for a spatial region and time interval of a specific action in a video





# Actions and motions

---

- Actions are usually defined by motions
- But many visually similar motions can have very different meanings and correspond to different actions



# Datasets

---



It is much easier to collect and annotate datasets for action recognition compared to object tracking or optical flow estimation



Kiss



Drink

# KTH Actions (2004)



Walking



Jogging



Runnin



Boxing



Waving



Clapping

- 25 people, 6 actions, 4 scenes (indoor, outdoor, outdoor with different scale, outdoor with different clothes)
- 2391 video

# UCF101 (2012)



- 13320 videos from Youtube in 101 classes
- Five groups: (1)Human-Object Interaction; (2) Body-Motion Only; (3) Human-Human Interaction; (4) Playing Musical Instruments; (5) Sports.
- Examples: to dye a lips, to tint eyes
- Accuracy from 43.9 (baseline Oct 2013) to 87.9% (Oct 2014)

Source: Khurram Soomro, Amir Roshan Zamir and Mubarak Shah, UCF101: A Dataset of 101 Human Action Classes From Videos in The Wild., CRCV-TR-12-01, November, 2012.



- 100 positive video clips per event category, 5000 negatives
- Testing on 98000 video clips, i.e. 4000 hours
- 20 known events, 10 adhoc events
- Videos from publicly available, user-generated content on various Internet sites
- Various descriptors for video, audio, text & speech recognition

# Kinetics



riding a bike




playing violin



braiding hair



dribbling basketball




riding unicycle



playing trumpet




brushing hair



dunking basketball

- large video dataset scraped from YouTube
- 400, 600, 700 classes
- 300k, 650k, 700k videos

# Two-stream CNN model



Temporal stream:

- Vertical and horizontal optical flow components
- 5-10 frames (input tensor  $w \cdot h \cdot 2L$  )
- Mean flow can be subtracted from each frame

# Самообучение




Figure 2: A diagram of **Dense Predictive Coding** method. The left part is the pipeline of the DPC, which is explained in Sec. 3.1. The right part (in the dashed rectangle) is an illustration of the Pred-GT pair construction for contrastive loss, which is explained in Sec. 3.2.

- Развитие self-supervised методов
- Учимся на задаче без разметки – предсказания признаков следующих видеофрагментов по предыдущим
- Нужно строить «похожие» на реальность



1. Введение в обработку и анализ видео
2. Оптический поток и его оценка
3. Распознавание событий в видео
4. Отслеживание одного объекта
5. Отслеживание множества объектов

# Visual object tracking (VOT)



- Произвольный объект выделен на первом кадре
  - Про него ничего не знаем, нет «детектора»
- Мы хотим отследить движение объекта во всех последующих кадрах
- Выход – «следы» (track) объектов, последовательность локаций в каждом кадре видео

# Сложность задачи



- Вычислительная нагрузка
  - Нужно обрабатывать  $N$  кадров в секунду
- Изменение по времени
  - Вид объекта меняется от кадра к кадру из-за ракурса, изменения освещения, внутренних изменений (скейтбордист)
- Взаимодействие объектов
  - Перекрытия объектов
  - Визуальное сходство объектов
  - И т.д.



# VOT Challenge

---



Основной конкурс для оценки методов визуального трекинга

<http://votchallenge.net/>

- Открытые реализации
- Оценка качества и скорости
- Небольшой, но разнообразный набор роликов
- Короткие ролики (100 frames)

Развитие:

- Добавление других модальностей (RGB + Depth, RGB + IR)
- Появление «долгого» отслеживания, с пропаданием и появлением объектов



# Примеры последовательностей

Most challenging:



Matrix



Rabbit



Butterfly

Least challenging:



Singer




Octopus



Sheep


Source: <http://votchallenge.net/>



*Bear-12: “white bear walking on grass around the river bank”*




*Bus-19: “red bus running on the highway”*



*Horse-1: “brown horse running on the ground”*




*Person-14: “boy in black suit dancing in front of people”*





*Mouse-6: “white mouse moving on the ground around another white mouse”*

- 1400 videos (YouTube CC license)
- 84s duration on average
- 3.5M frames in total
- 70 classes chosen for popular applications
- labelled by 10 volunteers and PhD students

# Стандартная схема итеративного трекинга




# Стандартная схема итеративного трекинга



Repeat for next pair of frames

... Previous frame → Current frame → Next frame


# GOTURN



Generic Object Tracking Using Regression Networks (GOTURN):

- Обучаем нейросеть на коллекции видео и изображений с bounding box
- Просто применяем её к паре кадров и за счёт этого получаем скорость 100 кадров/сек

# GOTURN network



Source: Held et.al. Learning to Track at 100 FPS with Deep Regression Networks, ECCV 2016

# Training GOTURN



Previous video frame  
centered on object



Current video frame, shifted  
with ground-truth bounding  
box



Image centered on  
object



Shifted image with ground-  
truth bounding box

Small shifts are sampled more often than large shifts

# STARK




Figure 2: Framework for spatial-only tracking.





Figure 3: Architecture of the box prediction head.



Two stage-training: first localization, then classification

Figure 4: Framework for spatio-temporal tracking. The differences with the spatial-only architecture are highlighted in pink.



1. Введение в обработку и анализ видео
2. Оптический поток и его оценка
3. Распознавание событий в видео
4. Отслеживание одного объекта
5. Отслеживание множества объектов

# Multiple object tracking (MOT)




- Работаем со множеством объектов
- На длительных промежутках времени
- Варианты :
  - Detection Based Tracking (DBT)
  - Detection Free Tracking (DFT)

# Выход MOT



- Набор траекторий объектов для всех объектов заданного типа, которые видны в видео
- Положение объекта обычно описывается с помощью bounding box

# Ошибки МОТ



- ID switches – для одной эталонной траектории выдается две и более траектории
  - Fragmentations – для одной эталонной траектории выдается две траектории с пропуском между ними, т.е. объект не виден на ряде кадров

# Метрики качества

---



Multiple Object Tracking Accuracy (MOTP) –  
надежность построения траектории

$$MOTA = 1 - \frac{\sum_t (FN_t + FP_t + IDSW_t)}{\sum_t GT_t}$$

Multiple Object Tracking Precision (MOTP) –  
точность локализации объектов

$$MOTP = \frac{\sum_{t,i} d_{t,i}}{\sum_t c_t}$$


# Метрики качества

---



- Mostly tracked (MT)
  - Объект успешно сопровождался  $> 80\%$  длины эталонной траектории
- Mostly lost (ML)
  - Объект успешно сопровождался  $< 20\%$  длины эталонной траектории
- Partially tracked (PT)
  - Все остальные

# HOTA



$$\text{Ass-IoU} = \frac{|\text{TPA}|}{|\text{TPA}| + |\text{FNA}| + |\text{FPA}|}$$

$$\begin{aligned} \text{AssA} &= \frac{1}{|\text{TP}|} \sum_{c \in \text{TP}} \text{Ass-IoU}(c) \\ &= \frac{1}{|\text{TP}|} \sum_{c \in \text{TP}} \frac{|\text{TPA}(c)|}{|\text{TPA}(c)| + |\text{FNA}(c)| + |\text{FPA}(c)|} \end{aligned}$$

$$\begin{aligned} \text{HOTA}_\alpha &= \sqrt{\text{DetA}_\alpha \cdot \text{AssA}_\alpha} \\ &= \sqrt{\frac{\sum_{c \in \text{TP}_\alpha} \text{Ass-IoU}_\alpha(c)}{|\text{TP}_\alpha| + |\text{FN}_\alpha| + |\text{FP}_\alpha|}} \end{aligned}$$

$$\begin{aligned} \text{HOTA} &= \int_{0 < \alpha \leq 1} \text{HOTA}_\alpha \\ &\approx \frac{1}{19} \sum_{\alpha=0.05}^{0.95} \text{HOTA}_\alpha \end{aligned}$$

# MOT20 Challenge

---



- 4 train and 4 test videos with challenging crowded scenes
- 14k frames, 9 minutes
- 1.5M and 0.7M bboxes for training and testing pedestrian detector



# Duke Multi-Target, Multi-Camera



- 8 static cameras x 85 minutes of 1080p 60 fps video
- More than 2,000,000 manually annotated frames
- More than 2,000 identities
- Manual annotation by 5 people over 1 year
- More identities than all existing MTMC datasets combined
- Unconstrained paths, diverse appearance


Source: <http://vision.cs.duke.edu/DukeMTMC>

# UA-DETRAC Benchmark




- 10 hours of videos, 25 fps, resolution 960×540 pixels
- 24 different locations at Beijing and Tianjin in China
- > 140000 frames
- 8250 vehicles
- 1.21M labeled boxes

# Detection by tracking



Детектирование объектов



Ассоциация обнаружений



Сопоставления  
обнаружения и траектории  
(треки)

# Типичные проблемы



- Ошибки детектора – пропуски обнаружений (FN) и ложные срабатывания
- Хороший трекер должен устранять эти проблемы
  - Заполнение пропусков в детекциях
  - Фильтрация ложных срабатываний

# Ограничения трекеров

---



- MOT Challenge findings:
  - 18% of tracks are not covered by detections at all
  - 37% of tracks are covered by low-confidence detections
  - Trackers reduce FP and raise FN
- Detector is a key!

# Важность хорошего детектора

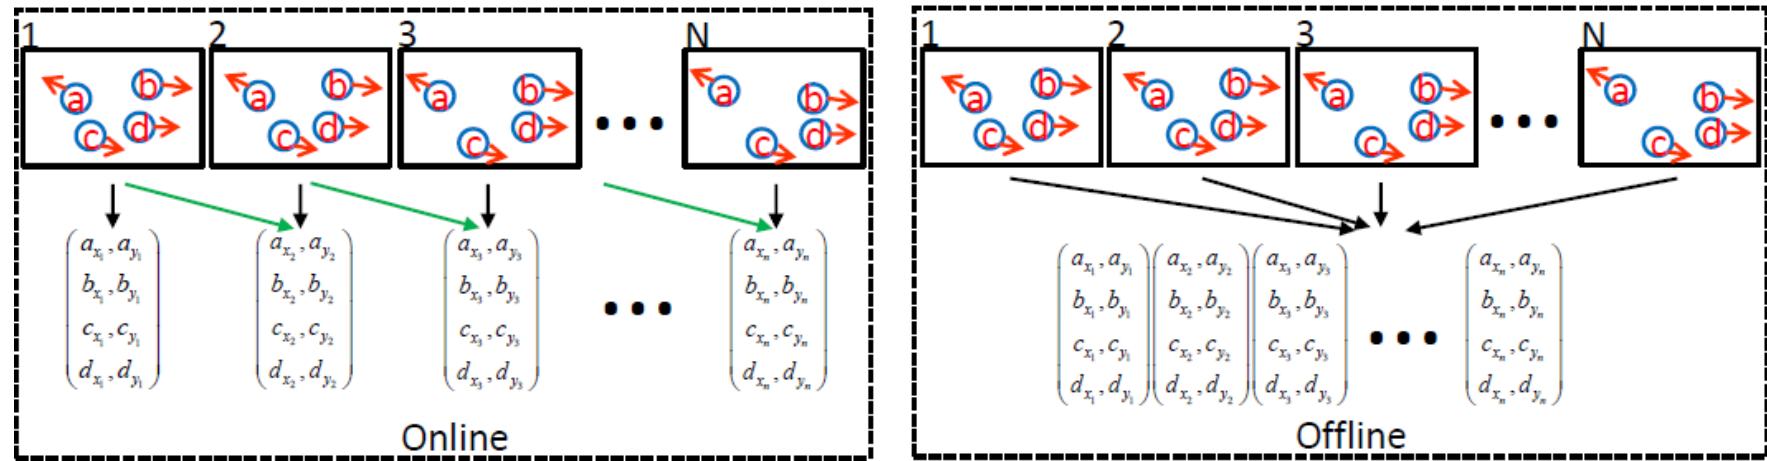


Tracker	Avg. Rank	↑MOTA	MOTP
<b>HCC</b> 1.	9.6	<b>49.3</b>	$\pm 10.2$ 79.0
<b>LMP</b> 2.	12.8	48.8	$\pm 9.8$ 79.0
<b>FWT</b> 3.	21.7	47.8	$\pm 9.4$ 75.5
			R. Henschel, L. I
<b>DeepSORT_2</b> 13.	10.3	61.4	$\pm 10.6$ 79.1
<b>TMO</b> 14.	10.6	61.4	$\pm 10.1$ 79.3
<b>SORTwHPD16</b> 15.	10.2	59.8	$\pm 10.3$ 79.6

With DPM  
(Deformable  
part models)  
detector

With Faster R-CNN  
detector

# Online vs offline tracking




On-line tracking

(Only current and previous frames are available)


Off-line (batch) tracking

(All frames (including future) are available)

# Data association




Two-frame methods




Multi-frame methods

# Компоненты функции сходства (affinity)



# Ассоциация прямо по IoU




Matching object in neighbouring frames by bounding box overlap

# Simple Online and Realtime Tracking (SORT)



- CNN-based object detector
- Kalman filter for prediction of object position in current frame based on positions in previous frames
- Hungarian algorithm for matching object detections in current frames with predicted positions
- IoU of detected and predicted bounding boxes as affinity measure for matching detection and track



# Influence of motion prediction



	MOTA	MOTP	MT	ML	FP	FN	ID sw	Frag	Hz
<b>SORT</b>	<b>59.8</b>	<b>79.6</b>	<b>25.4%</b>	<b>22.7%</b>	8698	<b>63245</b>	<b>1423</b>	<b>1835</b>	59.5
<b>IOU</b>	57.1	77.1	23.6%	32.9%	<b>5702</b>	70278	2167	3028	<b>3004</b>

Comparison of SORT to simple IoU tracker:

- Less False Negatives (FN), Fragmentations (Frag), ID Switches (ID Sw), Mostly Tracked (MT)
- Increase in MOTA and MOTP
- Increase in False Positive (bad)

# Re-identification



Detections in video



Probe



Gallery



Matches

# SORT + DA

---





	MOTA	MOTP	MT	ML	FP	FN	ID sw	Frag	Hz
<b>SORT</b>	59.8	79.6	25.4%	22.7%	<b>8698</b>	63245	1423	<b>1835</b>	<b>59.5</b>
<b>Deep SORT</b>	<b>61.4</b>	79.1	<b>32.8%</b>	<b>18.2%</b>	12852	<b>56668</b>	<b>781</b>	2008	40

Addition of re-identification to affinity between detections and tracks:

- Reduces ID switches (ID sw), False negatives (FN), Mostly Lost (ML) and increases Mostly Tracked (MT)
- Somewhat raises False Positives (FP) and Fragmentations (Frag)

# StrongSORT



Для начала  
улучшим базовые  
компоненты,  
включая детектор



# Дополнительные plug-in модули




Fig. 3: Framework of the two-branch AFLink model. It adopts two tracklets  $T_i$  and  $T_j$  as input, where  $T_* = \{f_k^*, x_k^*, y_k^*\}_{k=k^*}^{k^*+N-1}$  consists of the frame id  $f_k^*$  and positions  $(x_k^*, y_k^*)$  of the recent  $N = 30$  frames. Then, the temporal module extracts features along the temporal dimension with  $7 \times 1$  convolutions and the fusion module integrates information along the feature dimension with  $1 \times 3$  convolutions. These two tracklet features are pooled, squeezed and concatenated, and then input into a classifier to predict the association score.

Ассоциация удалённых треклетов




Fig. 4: Illustration of the difference between linear interpolation (LI) and the proposed Gaussian-smoothed interpolation (GSI).

«Грамотная» интерполяция траекторий  
между треклетами через сплайны

# Резюме

---



- 2 варианта видео – видеопоследовательность и видеопоток
- Движение – ключевой новый признак для распознавания по видео
- Мы рассмотрели 4 задачи анализа видео:
  - Оценку оптического потока
  - Распознавание действий и событий
  - Визуальное сопровождение объектов
  - Сопровождение множества объектов
- Все задачи сейчас успешно решаются нейросетевыми моделями
- Контекст (признаки изображения) и движение учитывают отдельно