

## Лекция 12. Практические примеры решения задач. Анализ поведения животных.

А. С. Коношин<sup>1</sup>   Д. П. Ветров<sup>2</sup>   Д. А. Кропотов<sup>3</sup>  
В. С. Коношин<sup>1</sup>   О. В. Барина<sup>1</sup>

<sup>1</sup>МГУ, ВМиК, лаб. КГ

<sup>2</sup>МГУ, ВМиК, каф. ММП

<sup>3</sup>ВЦ РАН

Спецкурс «Структурные методы анализа изображений и сигналов»

Трекинг одной мыши в клетке

Множественный трекинг мышей

Сегментация поведения на поведенческие акты

Структурный анализ поведения


Трекинг одной мыши в клетке

Множественный трекинг мышей

Сегментация поведения на поведенческие акты

Структурный анализ поведения


# Задача трекинга



Необходимо по видеозаписи поведения восстановить для каждого кадра:

- Контур мыши
- Характерные точки: нос, хвост, центр масс


# Определение контура мыши



Задача выделения контура мыши может быть решена с помощью разрезов графов, но есть способ проще:

- Определение фона:  $\text{Background} = \text{Median}(\text{Image}_1, \dots, \text{Image}_n)$
- Отсечение по порогу:  $\text{Mouse} = \text{Image}(\text{Image} < \alpha \cdot \text{Background})$

# Определение точек носа/хвоста



Пусть для каждого контура определены две точки, соответствующие носу и хвосту (две самые удаленные точки от центра).  $x_i = 0$ , если нос – первая точка,  $x_i = 1$ , если нос – вторая точка.

Оптимизационная задача:

$$Q = f(x_1) + \sum_{i=2}^N f(x_i, x_{i-1}) \rightarrow \min_{\{x_i\}}$$

$$f(x_i, x_{i-1}) = \angle(\mathbf{r}_1, \mathbf{r}_2) + \lambda \frac{\langle \mathbf{r}_2, \mathbf{v} \rangle}{\|\mathbf{v}\|^2}$$

# Определение точек носа/хвоста

Оптимизационная задача

$$Q = f(x_1) + \sum_{i=2}^N f(x_i, x_{i-1}) \rightarrow \min_{\{x_i\}}$$

Такая задача решается динамическим программированием.

Проход вперед:

$$V_1(x_1) = f(x_1);$$

$$V_i(x_i) = \min_{x_{i-1}} [V_{i-1}(x_{i-1}) + f(x_i, x_{i-1})]$$

$$S_i(x_i) = \arg \min_{x_{i-1}} [V_{i-1}(x_{i-1}) + f(x_i, x_{i-1})]$$

Проход назад:

$$x_N^* = \arg \min_{x_i} V_N(x_i)$$

$$x_i^* = S_{i+1}(x_{i+1}^*)$$

Трекинг одной мыши в клетке


Множественный трекинг мышей

Сегментация поведения на поведенческие акты

Структурный анализ поведения



# Задача множественного трекинга



Особенности задачи:

- Возможность полных перекрытий животных
- Необходимость определения дополнительно к форме животных положений точек носа и хвоста
- Необходимость использования простейших моделей движения мыши
- Необходимость обработки длительных видео

# Вычитание фона





$\text{Background} = \text{Median}(\text{Image}_1, \dots, \text{Image}_n)$

$\text{Mice} = \text{Image}(\text{Image} < \alpha \cdot \text{Background})$


Входная информация для алгоритма множественного трекинга – набор пятен для каждого кадра

# Модель мышцы


Модель мышцы — эллипс



# Определение количества мышей в блоках



# Транспортная задача (задача о назначении)




$$\begin{aligned} \sum_{i,j=1}^{N,M} c_{ij}x_{ij} &\rightarrow \min_{\{x_{ij}\}} \\ \sum_{j=1}^M x_{ij} &= a_i, \quad i = \overline{1, N} \\ \sum_{i=1}^N x_{ij} &= b_j, \quad j = \overline{1, M} \\ x_{ij} &\geq 0 \end{aligned}$$

При целочисленных  $a_i$  и  $b_j$  решение  $x_{ij}$  также получается целочисленным.

# Определение количества мышей в блоках

Предполагается, что в первый момент времени все мыши разделены



$$\sum_{i=0, j=1}^{N, M} c_{ij} x_{ij} \rightarrow \min_{\{x_{ij}\}}$$
$$\sum_{j=1}^M x_{ij} = a_i, \quad i = \overline{1, N}$$

$$\sum_{i=0}^N x_{ij} = b, \quad j = \overline{1, M}$$


$$x_{ij} \geq 0$$

$$b = \sum_{i=1}^N a_i, \quad a_0 = b(M - 1)$$

$$c_{0j} = 0, \quad j = \overline{1, M}$$

$a_i$  — число мышей в  $i$ -ом блоке в предыдущий момент времени  
 $b$  — максимально возможное число мышей в блоке в текущий момент времени

# Определение количества мышей в блоках



$$\sum_{i=0, j=1}^{N, 2M} c_{ij} x_{ij} \rightarrow \min_{\{x_{ij}\}}$$

$$\sum_{j=1}^{2M} x_{ij} = a_i, \quad i = \overline{1, N}$$

$$\sum_{i=0}^N x_{ij} = b_j, \quad j = \overline{1, 2M}$$

$$x_{ij} \geq 0$$

$$b_j = 1, \quad c_{0j} = +\text{inf}, \quad j = \overline{1, M}$$

$$b_j = \sum_{i=1}^N a_i - M, \quad j = \overline{M+1, 2M}$$

$$c_{0j} = 0, \quad j = \overline{M+1, 2M}$$


$$a_0 = (M - 1) (\sum_{i=1}^N a_i - M)$$

# Процедура разделения блоков

Оптимизационная задача:

$$p(\mathbf{e}_1, \mathbf{e}_2 | X) \propto p(X | \mathbf{e}_1, \mathbf{e}_2) p(\mathbf{e}_1) p(\mathbf{e}_2) \rightarrow \max_{\mathbf{e}_1, \mathbf{e}_2}$$

$X$  — точки блока,  $\mathbf{e}_1, \mathbf{e}_2$  — параметры эллипсов





# EM-алгоритм для разделения смеси распределений

$$p(\mathbf{x}) = \sum_{k=1}^M w_k \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \Sigma_k)$$

E-шаг:

$$\gamma(z_{ik}) = \frac{w_k \mathcal{N}(\mathbf{x}_i | \boldsymbol{\mu}_k, \Sigma_k)}{\sum_{j=1}^M w_j \mathcal{N}(\mathbf{x}_i | \boldsymbol{\mu}_j, \Sigma_j)}$$

M-шаг:

$$w_k = \frac{1}{N} \sum_{i=1}^N \gamma(z_{ik})$$

$$\boldsymbol{\mu}_k = \frac{1}{w_k N} \sum_{i=1}^N \gamma(z_{ik}) \mathbf{x}_i$$

$$\Sigma_k = \frac{1}{w_k N} \sum_{i=1}^N \gamma(z_{ik}) (\mathbf{x}_i - \boldsymbol{\mu}_k)(\mathbf{x}_i - \boldsymbol{\mu}_k)^T$$

## EM-алгоритм. E-шаг.

$X = \{\mathbf{x}_i\}$  — точки блоба

$C_k$  —  $k$ -ый эллипс,  $\mathbf{m}_k$  — его центр

$$\gamma(z_{ik}) = \begin{cases} 1, & \mathbf{x}_i \in C_k \text{ или } k = \arg \min_j \rho_M(\mathbf{x}_i, \mathbf{m}_j) \\ 0, & \text{иначе} \end{cases}$$

## EM-алгоритм. M-шаг.

Пусть  $\alpha$  — угол наклона наибольшей полуоси эллипса на предыдущем кадре

$\mathbf{y}_i$  — центрированные и повернутые на угол  $\alpha$  точки блога

Функция правдоподобия:

$$p(Y|A_k) = (\det A_k)^{n_k} \exp\left(-\frac{1}{2} \sum_i \mathbf{y}_i^T A_k \mathbf{y}_i\right)$$


Априорное распределение:

$$p(A_k|V, \nu) = \text{Const} (\det A_k)^{(\nu-3)/2} \exp\left(-\frac{1}{2} \text{tr}(V^{-1}A_k)\right)$$

В силу сопряженности точка максимума апостериорной плотности выписывается аналитически:

$$A_k = (n_k + \nu - 3) \left( \sum_i \gamma(z_{ik}) \mathbf{y}_i \mathbf{y}_i^T + V^{-1} \right)^{-1}$$

# Динамическое программирование для множественного трекинга



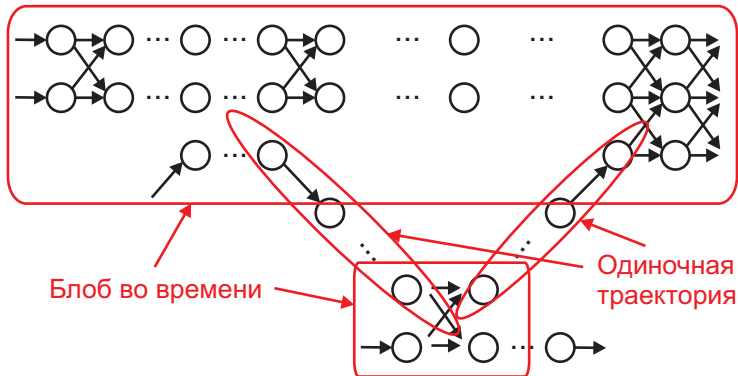
$x_i = (n_i, p_i)$ ,  $n_i \in \{1, \dots, K\}$  — номер мыши,  $p_i \in \{0, 1\}$  — индикатор точки носа. Размер функции Беллмана  $K!2^K$ .

Оптимизационная задача:

$$Q = f(x_1) + \sum_{i=2}^N f(x_i, x_{i-1}) \rightarrow \min_{\{x_i\}}$$

$$f(x_i, x_{i-1}) = \angle(\mathbf{r}_1, \mathbf{r}_2) + \lambda_1 \frac{\langle \mathbf{r}_2, \mathbf{v} \rangle}{\|\mathbf{v}\|^2} + \lambda_2 \rho(\mathbf{m}_1, \mathbf{m}_2)$$

# Структура данных, блоки во времени



Предположение: в каждый момент времени в группу мышей могут либо добавляться либо отниматься одиночные мыши

# Этапы алгоритма

- Определение количества мышей в каждом блоке
- Определение точек носа/хвоста для траекторий одиночных мышей
- Разделение блоков на набор эллипсов
- Идентификация и определение точек носа/хвоста внутри блоков во времени
- Сшивка траекторий мышей
- Окончательное определение точек носа/хвоста для полных траекторий

# Сделанные предположения

- Все мыши на первом кадре разделены
- Мыши хорошо описываются эллипсами
- При слипании мышей в каждый момент времени происходит только прибавление мышей к общей группе или удаление мышей из общей группы, причем добавляются или удаляются только одиночные мыши

# План

Трекинг одной мыши в клетке



Множественный трекинг мышей

Сегментация поведения на поведенческие акты

Структурный анализ поведения



# Постановка задачи





По наблюдаемым данным  $X$  разбить сигнал на набор сегментов  $[s_i + 1, s_{i+1}]$ , соответствующих отдельным поведенческим актам  $t_i \in \{\text{Grooming, Climbing, } \dots, \text{Running}\}$ .

Для решения используем скрытые марковские модели.

# Признаковое пространство

Признаки, вычисляемые по данным видеотрекинга:

- Величина скорости
- Величина ускорения
- Угол между скоростью и ускорением
- Расстояние до края/центра арены
- Проекция на собственные контура
- И т.д.




# Априорное распределение на длину одного сегмента

В классической СММ априорная вероятность нахождения в состоянии  $t$  ровно  $d$  моментов времени составляет

$$p_t(d) = (A_{tt})^d (1 - A_{tt})$$

Здесь  $A_{tt}$  — вероятность остаться в состоянии  $t$  в каждый момент времени.



Поведенческие акты не могут быть очень короткими, поэтому более адекватной моделью будет сдвинутое геометрическое распределение.

# План


Трекинг одной мыши в клетке

Множественный трекинг мышей

Сегментация поведения на поведенческие акты

Структурный анализ поведения

# Композитно-иерархическая СММ



Здесь  $t_i \in \{0, 1\}$  — факт активности  $i$ -ого эмоционального контура,  
 $z_i \in \{1, \dots, K\}$  — поведенческие акты, ограничения композитности:


$$\begin{aligned} \sigma = \tau &\Rightarrow p(z_n = \zeta | z_{n-1} = \eta, T_n = \sigma, T_{n-1} = \tau) = \\ &= \frac{1}{|N(\sigma)|} \sum_{i \in N(\sigma)} p(z_n = \zeta | z_{n-1} = \eta, T_n = \sigma_i, T_{n-1} = \tau_i) \end{aligned}$$

$$\begin{aligned} \sigma \neq \tau &\Rightarrow p(z_n = \zeta | z_{n-1} = \eta, T_n = \sigma, T_{n-1} = \tau) = p(z_1 = \zeta, T_1 = \sigma) = \\ &= \frac{1}{|N(\sigma)|} \sum_{i \in N(\sigma)} p(z_1 = \zeta, T_1 = \sigma_i) \end{aligned}$$

# Задачи анализа композитно-иерархической СММ

**Сегментация.** Решается прямой модификацией алгоритма Витерби.

**Обучение без учителя.** E-шаг EM-алгоритма на основе алгоритма sum-product.



На M-шаге необходимо учесть ограничения композитности при пересчете  $w$  и  $A$ . Можно реализовать с использованием итерационного процесса.