

Автоматическая сегментация поведения лабораторных животных на основе выделяемых контуров*

Ломакина-Румянцева Е. И., Ветров Д. П., Кропотов Д. А.
lr2kate@gmail.com

МГУ им. М. В. Ломоносова, ВМК; Вычислительный Центр РАН

Предлагается использовать при сегментации поведения животного на поведенческие акты информацию о контуре животного в каждый момент времени. Сегментация осуществляется с помощью алгоритма на основе скрытых марковских моделей с использованием априорного распределения длины сегмента.

Введение

Необходимость создания высокопроизводительных и экономически эффективных методов поведенческого фенотипирования (скрининга) лабораторных мышей привела к появлению автоматических домашних клеток, предоставляющих исследователям возможность оказывать на мышью различные стимулирующие воздействия, и оборудованных системами видеонаблюдения [2]. Однако это привело к взрывному росту сложности и временных затрат на анализ данных. Современные методы анализа поведения, например выделение поведенческих шаблонов и стереотипии [1], требуют разделения траекторий движения на отдельные поведенческие акты. Эта задача в настоящее время может быть выполнена только с привлечением опытного специалиста в области поведения животных. Существующие системы видеонаблюдения за поведением животных позволяют определять некоторые акты с помощью простейших эвристических метрик, например, сравнивая длину мыши с порогом, что обеспечивает крайне низкую точность распознавания. Автоматические методы сегментации траекторий на данный момент позволяют выделять только периоды двигательной активности и неподвижности, требуют тщательной настройки параметров, что существенно ограничивает их применимость на практике [3].

Использование метода скрытых марковских моделей для автоматической сегментации поведения лабораторных животных показало многообещающие результаты [4]. В данной работе для сегментации используется признаковое пространство, расширенное с помощью информации о контуре животного в каждый момент времени.

Признаковое пространство

Многие системы видеотрекинга позволяют выделять только координаты точки, соответствующей центру масс животного. На основе этих данных рассчитываются такие признаки как скорость, ускорение, дисперсия скорости и ускорения, кривизна движения. При дополнительном выделении координат носа и точки прикрепления хвоста ста-

новится возможным рассчитать также «вытянутость» животного, угол поворота головы, изменение этого угла и т. п.

Все эти признаки, безусловно, использовались при экспериментах, однако было решено расширить признаковое пространство для улучшения результатов. Система видеотрекинга, используемая в данной работе, позволяет выделять в каждый момент времени не только координаты уже упомянутых трёх точек, но и контур животного. Выделение контура осуществляется на основе моделей активной формы [5]. Для получения обучающего набора все контуры центрируются и поворачиваются вокруг центра таким образом, чтобы точка носа лежала на оси x . Затем для каждого контура через одинаковые интервалы берётся N точек. В соответствующий каждому контуру вектор размерности $2N$ сначала записываются координаты x всех точек, а затем координаты y . На рис. 1 приведён пример нахождения контура животного со взятыми на нём $2N$ точками. К получившемуся набору применяется метод главных компонент [6], т. е. вычисляются характерные изменения контура.




Рис. 1. Пример выделения контура животного.

Обозначим за $x_i \in \mathbb{R}^{2N}$ контур животного в момент времени i , а за $\tilde{x}^k \in \mathbb{R}^{2N}$ — контур k -го животного из обучающего набора. Тогда под $\bar{x} = \frac{1}{M} \sum_{k=1}^M \tilde{x}^k$ будем понимать математическое ожидание контура, то есть среднестатистический контур, а главные компоненты набора будем обозначать $y_i \in \mathbb{R}^{2N}$. Тогда дополнительные l признаков в момент вре-

*Работа выполнена при финансовой поддержке РФФИ, проект № 08-01-00405.

мени i будут вычисляться следующим образом:

$$f_i^k = (x_i - \bar{x})^T y_k, \text{ где } k = 1, \dots, l.$$

По результатам экспериментов было решено взять $l = 5$, так как выборочная дисперсия существенно падает после пятой главной компоненты. На рис. 2 и 3 приведены примеры изменений контура относительно среднестатистического контура, соответствующих первой и второй главным компонентам.




Рис. 2. Первая и вторая главные компоненты.

Метод сегментации

В данной работе для сегментации траектории использовался подход, основанный на скрытых марковских моделях [7]. Скрытые марковские модели являются примером вероятностной модели для обработки последовательностей событий и часто используются для анализа и сегментации сигналов. Предполагается, что мышь в каждый момент времени находится в одном из состояний поведения, которые характеризуются вектором признаков, вычисляемых по траектории, полученной с помощью системы видеотрекинга. Каждое такое состояние трактуется как ненаблюдаемое (скрытое) состояние марковского процесса. Параметры процесса оцениваются по выборке, составленной из траекторий, размеченных экспертом. Помимо этого, учитывается априорное распределение длины сегмента, в течение которого мышь находится в одном состоянии.

В имевшихся выборках экспертами было выделено 9 различных поведенческих актов, часть из которых была сгруппирована в обобщённые состояния. Основанием для группировки являлась частота встречаемости состояния. Окончательно множества состояний выглядели следующим образом: **Run** (бег, ходьба), **Turns** (повороты головы и тела), **Rears** (стойки на задних лапах), **Quiet** (состояние покоя), **Groom** (умывание).

Сегментация новой траектории осуществляется вычислением наиболее вероятной последовательности фаз, основанной на признаках, рассчитанных для каждого момента времени.

Описание алгоритма

Обозначим через $\bar{x}(t) \in \mathbb{R}^d$ наблюдаемый вектор признаков, вычисляемый по траектории мыши для каждого момента времени $t = 1, \dots, T$. Пусть $z(t) \in$

$\{z_1, \dots, z_k\}$ — обобщённое состояние (фаза) мыши в момент времени t .

Необходимо найти вектор

$$(z^*(1), \dots, z^*(T)) = \arg \max_{(z(1), \dots, z(T))} p(\bar{x}(1), \dots, \bar{x}(T), z(1), \dots, z(T)).$$

Пусть наблюдаемая траектория $\mathbf{x}(t)$ разбита на S сегментов, соответствующих состояниям $z^1, \dots, z^S \in \mathbb{Z}$. Обозначим через t_i время начала каждого сегмента, $t_0 = 1$, $t_S = T$. Таким образом, на участке от t_{i-1} до $t_i - 1$ обобщённое состояние для всех элементов последовательности равно z^i . Пусть, кроме того, известно некоторое априорное распределение $p_{Y_j}(\tau)$ длины сегмента τ для каждого состояния Y_j .

Тогда вероятность разбиения выглядит следующим образом:

$$\begin{aligned} p(\bar{x}(1), \dots, \bar{x}(T), z(1), \dots, z(T)) &= \\ &= p(z^1) \prod_{i=1}^{S-1} p_{z^i}(t_i - 1 - t_{i-1}) \prod_{t=t_{i-1}}^{t_i-1} p(\bar{x}(t) | z^i) \times \\ &\times \prod_{i=2}^S p(z^i | z^{i-1}) \prod_{t=t_{S-1}}^{t_S} p(\bar{x}(t) | z^S) \left(\sum_{\tau=t_S-t_{S-1}}^{+\infty} p_{z^S}(\tau) \right). \end{aligned}$$

Последний множитель учитывает, что последний сегмент может продолжаться сколь угодно долго вне пределов нашего измерения.

Для оценки плотности вероятности $p(\bar{x}(t) | z(t))$ для каждой фазы $\{z_1, \dots, z_k\}$ воспользуемся следующим методом. Приведём сначала набор признаков к некоррелированному виду с помощью метода главных компонент. Обозначим преобразованные признаки $g(t) = Q\bar{x}(t)$, где $Q^T = Q^{-1}$ — ортогональная матрица перехода к новому базису, а $E\bar{g}(t)\bar{g}(t)^T = \text{diag}(\lambda_1^2, \dots, \lambda_d^2)$. Теперь для каждой фазы построим одномерную оценку плотности значений преобразованных признаков $\hat{p}(g^i(t) | z(t) = z_j)$, $i = 1, \dots, d$, $j = 1, \dots, k$. Для этого гистограмму распределения обучающей выборки для каждого состояния и каждой главной компоненты приблизим смесью из пяти нормальных распределений с помощью EM-алгоритма [8]. Гистограмма распределения значений $g^1(t)$ и соответствующая ей аппроксимация пятью гауссианами для фазы **Groom** изображена на рис. 4. Совместная плотность распределения признаков при данной фазе оценивалась как произведение одномерных оценок плотностей распределения $g^i(t)$:

$$\hat{p}(\bar{x}(t) | z(t)) = \hat{p}(\bar{g}(t) | z(t)) = \prod_{i=1}^d \hat{p}(g^i(t) | z(t)).$$

Вероятность перехода из фазы z_i в фазу z_j и априорная вероятность каждого состояния легко




Рис. 3. Гистограмма распределения значений $g^1(t)$ и соответствующая ей аппроксимация для фазы Groom.

оцениваются следующим образом:

$$\hat{p}(z(t)=z_j | z(t-1)=z_i) = \frac{|\{t: z(t)=z_j, z(t-1)=z_i\}|}{|\{t: z(t-1)=z_i\}|},$$

$$\hat{p}(z(1)=z_i) = \frac{|\{t: z(t)=z_i\}|}{T}.$$

В классическом методе скрытых марковских моделей предполагается, что вероятность длины сегмента τ задаётся следующим образом:

$$p_{Y_j}(\tau) = (1 - p(Y_j|Y_j))p(Y_j|Y_j)^{\tau-1}, \quad \tau > 0.$$

В данной работе под априорной вероятностью длины сегмента τ будем понимать следующее

$$p_{Y_j}(\tau) = \begin{cases} 0, & \text{если } \tau < k_0, \\ (1 - p(Y_j|Y_j))p(Y_j|Y_j)^{\tau-k_0}, & \text{если } \tau \geq k_0, \end{cases}$$

где k_0 — минимально допустимая длина сегмента. Также для проведения процедуры сегментации нам потребуется знать значение величины $\sum_{\tau=t}^{+\infty} p_{Y_j}(\tau)$. Можно показать, что:

$$\sum_{\tau=t}^{+\infty} p_{Y_j}(\tau) = \begin{cases} 1, & \text{если } t < k_0, \\ p(Y_j|Y_j)^{\tau-k_0}, & \text{если } t \geq k_0. \end{cases}$$

Здесь, как и в предыдущей формуле, k_0 — минимально допустимая длина сегмента. Построение оптимальной сегментации сводится к максимизации вероятности разбиения.

Для дальнейших построений введём функцию Беллмана $V_t(Y_j)$ для каждого момента времени t и состояния Y_j как вероятность наилучшей сегментации от момента времени t_0 до момента времени t , заканчивающейся в состоянии Y_j , следующим образом:

$$V_t(Y_j) = \max \left\{ f(Y_j), \max_{Y_i \neq Y_j} g(Y_j) \right\}.$$

Здесь $f(Y_j)$ — вероятность наилучшей сегментации от момента времени t_0 до момента времени

$t-1$, заканчивающейся в состоянии Y_j , при сохранении состояния Y_j в момент времени t ; а $g(Y_j)$ — вероятность наилучшей сегментации от момента времени t_0 до момента времени $t-1$, заканчивающейся в состоянии Y_i , с переходом в состояние Y_j в момент времени t . Можно показать, что:

$$f(Y_j) = V_{t-1}(Y_j) + \log p(\bar{x}(t)|Y_j) +$$

$$+ \log \sum_{\tau=t-t(Y_j)}^{+\infty} p_{Y_j}(\tau) - \log \sum_{\tau=t-t(Y_j)-1}^{+\infty} p_{Y_j}(\tau);$$

$$g(Y_j) = V_{t-1}(Y_j) + \log p(\bar{x}(t)|Y_j) + \log p(Y_j|Y_i) +$$

$$+ \log p_{Y_j}(t-t(Y_j)-1) - \log \sum_{\tau=t-t(Y_j)-1}^{+\infty} p_{Y_j}(\tau).$$

Здесь $t(Y_j)$ обозначает начало сегмента, в который входит момент времени $t-1$, для каждого состояния Y_j . Обозначим через $S_t(Y_j)$ предшествующую точку оптимальной сегментации.

$$S_t(Y_j) = \begin{cases} Y_j, & \text{если } f(Y_j) > \max_{Y_i \neq Y_j} g(Y_j), \\ \arg \max_{Y_i \neq Y_j} g(Y_j), & \text{иначе.} \end{cases}$$

Тогда можно последовательно вычислить значения функции Беллмана и функции $S_t(Y_j)$ для всех моментов времени $1 \leq t \leq T$. Выполняя обратный проход, получаем оптимальную разметку траектории

$$(z^*(T), z^*(T-1), \dots, z^*(1)) =$$

$$= (\arg \max_{Y_j} V_T(Y_j), S_T(z^*(T)), \dots, S_2(z^*(2))).$$

Эксперименты и будущая работа

Предложенная система была протестирована на 13 видеозаписях изучающего поведения мышей полёвок в эксперименте «открытое поле», общее время записи — 325 минут. Из них 150 минут были использованы как обучающая выборка, остальные — как контрольная. Результаты автоматической сегментации были сопоставлены с сегментацией, выполненной вручную, см. таблицу 1, где в каждой ячейке указано соответствующее число кадров.

Таблица 1. Матрица точности распознавания фаз поведения мыши.

Реальный класс:	Groom	Quiet	Run	Turns
Класс. как:				
Groom	5683	7120	22	599
Quiet	2097	100859	95	283
Run	0	21	9890	796
Turns	850	7281	356	10382

Общий процент ситуаций совпадения экспертной разметки и результата работы алгоритма составил 87.8%. Лучше всего распознаётся фаза Run. Также, благодаря выделению контуров, стабильно распознаётся фаза Turns. Существуют некоторые трудности с распознаванием фаз Quiet и Groom, что связано с визуальной схожестью этих поведенческих актов.

В дальнейшем планируется поставить ряд экспериментов с обучением без учителя для выявления участков стационарного поведения, не связанных с поведенческими актами, которые выделяются экспертами.

Литература

- [1] *Magnus S. Magnusson* Discovering hidden time patterns in behavior: T-patterns and their detection // Behavior Research Methods, Instruments & Computers. — 2000. — Т. 32, № 1. — С. 93–110.
- [2] *Spruijt B.M., DeVisser L.* Advanced behavioral screening: automated home cage ethology // Drug Discovery Today: Technologies — 2006. — Vol. 3, № 2. — Pp. 231–237.
- [3] *Cherepov A.B., Mukhina T.V., Anokhin K.V.* Automatic segmentation of mouse behavior during video tracking in home cages // 5th Int. Conf. on Methods and Techniques in Behavioral Research «Measuring Behavior 2005», Wageningen, 2005.
- [4] *Konushin A., Kropotov D., Vetrov D., Lomakina-Rumyantseva E., Zarayskaya I., Anokhin K., Voronin P., Sindeyev M., Kutuzova V.* Система видеонаблюдения за поведением лабораторных животных с автоматической сегментацией на поведенческие акты // Proceedings of GraphiCon'2008, Moscow, 2008 — Pp. 199–205.
- [5] *Voronin P., Konushin A.* Video tracking laboratory rodents using active shape models // 9th Int. Conf. on Patterns Recognition and Image Analysis: New Information Technologies «PRIA-9-2008», Nizhni Novgorod, 2008. — Pp. 299–302.
- [6] *Jolliffe I.T.* Principal Component Analysis, Series: Springer Series in Statistics, 2nd ed. — Springer, 2002.
- [7] *Elliot R.J., Aggoun L., Moore J.B.* Hidden Markov Models: Estimation and Control. — Springer, 1995.
- [8] *Dempster A., Laird N., Rubin D.* Maximum likelihood from incomplete data via the em algorithm // Journal of the Royal Statistical Society. — 1977. — Т. 39, № 1. — С. 1–38.