

Автоматическое распознавание ЖЯ

С. Мартынова

27 апреля 2018 г.

SL reading group (НИУ ВШЭ)

Распознавания движений головы

Существует два подхода в исследованиях, которые рассматривают задачу автоматического распознавания движений головы.

1. используются данные, в которых лицо или его часть отслеживаются с помощью различных устройств и на таких данных, как правило, моделируют HMM модели.
2. движения головы выделяют из необработанных видео-данных с использованием различных видеотехнологий. (результаты очень сильно зависят от качества видео, освещения.
используемые модели: LDCRF, SVM и HMM)

Распознавание движений головы (Paggio et al. [2017])

Фичи, которые надо выделять

- ▶ скорость — изменение положения головы в единицу времени
- ▶ ускорение — изменение скорости в единицу времени
- ▶ рывок/толчок — изменение ускорения в единицу времени

Т.е. ожидается, что последовательность кадров, для которых рывок в горизонтальном или вертикальном положении имеет высокое значение, будет соответствовать самой сильной части движения головы (это ещё называется штрихом).

Данные

Датский видеокорпус NOMCO, в котором в том числе размечены движения головы: кивки, повороты и т.д.

Выбраны два видео с одним и тем же носителем. Одно для обучения, а второе для тестирования.

В обоих видеороликах используется библиотека OpenCV. Производится анализ каждого кадра (рассматриваются координаты головы x и y , на основании этих координат вычисляются скорость, ускорение и рывки для каждого кадра. затем эта информация добавляется в аннотацию + для каждого кадра добавляется информация о наличии или отсутствии в нем движения головы).

Обучение

Затем был обучен классификатор SVM (метод опорных векторов)
При таком алгоритме и фичами удалось достигнуть 68% точности классификации жестов головы.

Дальше в этой работе попробовали улучшить baseline при помощи добавления информации о речи говорящего (но это не наш случай).

Head Movement Recognition

методы определяющие положение головы

1. отслеживание лица на видео (Rowley et al. [1998]) (нейронная сеть разбивает изображение на маленькие кусочки и решает, относятся ли они к объекту "лицо")
2. метод, в котором строится 3D-модель позы головы путем вычисления областей кожи и волос на изображении (Chen et al. [1998]) (сначала делают изображение однотонным, потом при помощи какого-то своего алгоритма находят кожу и волосы, затем вычисляется площадь этих областей).
3. метод, основанный на отслеживании глаз. (Tian et al. [2000])

Общая информация

проблемы SLR

- ▶ некоторые жесты трудно отличить друг от друга
- ▶ скорость жестикуляции может различаться
- ▶ размер ладони у разных людей существенно отличается
- ▶ следует учитывать такие факторы, как разные цвета кожи у людей и изменения освещенности
- ▶ распознавание жестов необходимо осуществлять в реальном времени
- ▶ несмотря на правила, каждому человеку свойственны свои особенности жестов (вариативность)

проблемы SLR

- ▶ хотя большинство жестов одноручные, они так же могут быть двуручными
- ▶ система должна определять доминирующую руку
- ▶ руки могут перекрывать друг друга или лицо



(a) LEARNING



(b) CONFERENCE



(c) FOOD



(d) DATE

Что важно?

На что нужно обратить внимание?

- ▶ форма рук
- ▶ позиция рук
- ▶ движение само по себе
- ▶ выражение лица
- ▶ положение тела
- ▶ ритм "жестопроизводства"

Наиболее популярные методы распознавания жестов

- ▶ 3D-распознавание (алгоритмы, использующие шарнирную модель человеческой руки для определения ключевых параметров, например, скелетный метод)
- ▶ использование внешнего подобия



Дополнительные инструменты для SLR

- ▶ Microsoft Kinect (←PrimeSense)
- ▶ беспроводные перчатки, оснащенные сенсором (минусы: неуклюжесть жестов, высокая стоимость перчаток)
- ▶ трехмерный сенсор ASUS Xtion PRO (←PrimeSense)

Преимущество трехмерных сенсоров относительно цветных видеокамер:

- ▶ устойчивость к изменениям освещения
- ▶ возможность получения дальностного изображения, каждый пиксель которого характеризуется расстоянием до сенсора
- ▶ наличие библиотек, позволяющих распознавать позиции рук, ног и головы человека, а именно OpenNI и Nite

РЖЯ — дактиль

Автоматическое преобразование жестов русской ручной азбуки в текстовый вид

Опираются на концепции, изложенные в системах Hamburg Notation System и SignWriting.

В SignWriting 261 конфигурация руки. В дактиле используются 26 из них, которые образуют множество $S = (s_1, s_2, \dots, s_{26})$

При показе жестов Ё и К конфигурация руки меняется =>

- ▶ вместо буквы Ё используется E
- ▶ вместо жеста буквы К используется жест с конфигурацией s_{10} , но отсутствием движения

В SignWriting насчитывается > 500 разных движений, совершаемых во время жестикуляций, которые обозначаются через множество $M = (m_0, m_1, m_2, \dots, m_7)$


Таким образом любой жест представляет собой элемент из множества $S \times M$. Например, буква А — это элемент (s_1, m_0) , Щ — (s_{21}, m_6) .

Конфигурация и движение

Обозначение	S ₁	S ₂	S ₃	S ₄	S ₅	S ₆	S ₇	S ₈	S ₉
Форма руки									
Обозначение	S ₁₀	S ₁₁	S ₁₂	S ₁₃	S ₁₄	S ₁₅	S ₁₆	S ₁₇	S ₁₈
Форма руки									
Обозначение	S ₁₉	S ₂₀	S ₂₁	S ₂₂	S ₂₃	S ₂₄	S ₂₅	S ₂₆	
Форма руки									


Обозначение	m ₀	m ₁	m ₂	m ₃	m ₄	m ₅	m ₆	m ₇
Движение								

Схема работы системы автоматического перевода



Обработка видеокadra


- ▶ При помощи OpenNI и Nite выделяется рука посредством создания сферы вокруг искомой точки и удаления всех точек, лежащих вне её.
- ▶ изображение представляется в виде плоской полутоновой картинке, которая получается специальным преобразованием исходного дальностного изображения




Вычисление ключевых характеристик руки

- ▶ конфигурация руки 
- ▶ позиция верхней точки руки (т.е. точка, имеющая максимальную ординату) 


Для распознавания формы руки используется метод построения и анализа скелета руки. В данной работе для идентификации сравнивается скелет руки с эталонным → для сравнения выполняется развертка скелетов.



(a)



(b)



(c)

Результаты классификатора конфигураций руки

- ▶ точность — доля конфигураций руки, действительно принадлежащих данному классу относительно всех конфигураций, которые система отнесла к этому классу (средняя точность — 83,4%)
- ▶ полнота — доля найденных классификатором конфигураций принадлежащих классу относительно всех конфигураций этого класса в тестовой выборке (средняя полнота — 76,7%)

Качество	s_1	s_2	s_3	s_4	s_5	s_6	s_7	s_8	s_9	s_{10}	s_{11}	s_{12}	s_{13}	s_{14}	s_{15}	s_{16}	s_{17}	s_{18}	s_{19}	s_{20}	s_{21}	s_{22}	s_{23}	s_{24}	s_{25}	s_{26}
Точность	1	1	.61	1	.61	.88	.9	.49	.61	0.8	.95	1	1	1	.91	.78	.78	.59	.74	.95	.43	.95	.71	1	1	1
Полнота	.95	.4	.95	.2	.95	.75	.9	.95	.95	0.6	.9	.8	.95	.5	.5	.7	.9	.95	.85	.95	.8	.95	.6	.65	.85	.5

Проблема коартикуляции


Коартикуляция — это артикуляция со слиянием конечной фазы жеста с начальной фазой следующего жеста.

Для сегментирования непрерывных динамических жестов руки и нахождения коартикуляций


- ▶ используют данные о позиции ладони, т.е. жест завершен, когда ладонь в течение короткого времени не меняет свою позицию
- ▶ используются условные случайные поля (Conditional Random Field, CRF — это статистический метод классификации, характерным отличием которого является возможность учитывать «контекст» классифицируемого объекта.)
- ▶ Скрытые Марковские Модели (НММ)
- ▶ и т. д.

Изменения формы руки во время показа слова "добрый"

- ▶ T — это упорядоченное множество отсчетов-кадров приходящихся на сеанс показа отдельного слова или предложения
- ▶ S — изменение формы руки



SignAll — это автоматический переводчик для ASL. Inroduction video.



Спасибо за внимание!

Пишите письма

lena@ales.ru

alex250396@gmail.com

Список литературы

- Chen, Qian, Haiyuan Wu, Takeshi Fukumoto, Masahiko Yachida (1998). 3d head pose estimation without feature tracking. In *Automatic Face and Gesture Recognition, 1998. Proceedings. Third IEEE International Conference on*, pp. 88–93. IEEE.
- Paggio, Patrizia, Costanza Navarretta, Bart Jongejan (2017). Automatic identification of head movements in video-recorded conversations: can words help? In *Proceedings of the Sixth Workshop on Vision and Language*, pp. 40–42.
- Rowley, Henry A, Shumeet Baluja, Takeo Kanade (1998). Neural network-based face detection. *IEEE Transactions on pattern analysis and machine intelligence* 20(1), 23–38.
- Tian, Ying-li, Takeo Kanade, Jeffrey F Cohn (2000). Dual-state parametric eye tracking. In *Automatic Face and Gesture Recognition, 2000. Proceedings. Fourth IEEE International Conference on*, pp. 110–115. IEEE.