

Методы анализа движений человека на основе показаний сигналов с сенсоров

Филиппова Анастасия

Московский физико-технический институт
Физтех-школа прикладной математики и информатики
Кафедра интеллектуальных систем

Научный руководитель д.ф.-м.н. В. В. Стрижов
Научный консультант Р. Нейчев
Москва,
2021 г.



Построение признакового описания временного ряда

Требуется

Построить модель, задающую отображение из пространства временного ряда сигнала в пространство меньшей размерности.

Модель должна удовлетворять следующим свойствам:


- расстояние между получаемыми векторными представлениями сигнала, соответствующие одинаковым активностям человека меньше расстояния между различными;
- качество работы модели оценивается по активностям, которых не было в обучении.

Предлагается

Построить нейросетевую модель для решения задачи построения репрезентативного признакового описания сегмента временного ряда сигнала.

- 1 Построение признакового пространства на основе статистик
(*Time Series Analysis, William W.S. Wei*)
- 2 Построение признакового пространства, используя частотные характеристики сигнала
 - Дискретное преобразование Фурье
 - Wavelet преобразование
(*Mathematical principles of signal processing: Fourier and wavelet analysis, P Brémaud; Wavelet analysis: theory and applications, Daniel T.L. Lee and Akio Yamamoto*)
- 3 Решение задачи классификации временных рядов
 - SVM, Random Forest
 - Нейросетевые модели
(*Human activity recognition by wearable sensors: Comparison of different classifiers for real-time applications, G De Leonardi, Samanta Rosat; Enhanced human activity recognition based on smartphone sensor data using hybrid feature selection model, N Ahmed, JI Rafiq*)

Временные ряды сигналов



Сигнал, полученный с носимого устройства в течение активности приседания.

$a^t = (a_t^x, a_t^y, a_t^z)^T \in \mathbb{R}^3$, $g^t = (g_t^x, g_t^y, g_t^z)^T \in \mathbb{R}^3$, $l_t \in \mathbb{L}$ — показания акселерометра, гироскопа и метка активности в момент времени t .

$X = \begin{bmatrix} a \\ g \end{bmatrix} \in \mathbb{R}^{6 \times T}$, l - временной ряд сигнала и меток активностей.

Формирование обучающей выборки

Разбиение на сегменты

Временной ряд сигнала X разбивается на пересекающиеся сегменты длины w с фиксированным шагом s : $X_{t,t+w-1} = (X_t, \dots, X_{t+w-1}) \in \mathbb{R}^{6 \times w}$ - m -ый сегмент.

Разметка активностей

Каждому сегменту ставим в соответствие метку активности по правилу:
 $X_{t,t+w-1}: l_{t,t+w-1} = \text{mode}(l_{t,t+w-1})$.

Полученная выборка

$\{(X_m^i, l_m^i)\}_{m=0}^{\lfloor \frac{T_i}{s} \rfloor}$, где $i \in [0, n]$, n - число экспериментов, T_i - время i -ого эксперимента.

Задача выбора модели

Рассматривается множество параметрических моделей \mathfrak{F} :

$$\mathfrak{F} = \{f: (w, X_m) \rightarrow v\},$$

$$f = \arg \min_{f \in \mathfrak{F}} \mathcal{L},$$

где $X_m \in \mathbb{R}^{w \times b}$ – исходный сегмент, $v \in \mathbb{R}^d$, – векторное представление сегмента сигнала, w – параметры модели, \mathcal{L} целевая функция потерь (Triplet Loss Function).

$$L(a, n, p) = \max(\|f(X_a) - f(X_p)\|^2 - (\|f(X_a) - f(X_n)\|^2 + \text{margin}), 0),$$

X_a, X_p – сегменты одного класса (одна активность), X_a, X_n – сегменты разных классов.

$$\mathcal{L} = \sum_{a,n,k} [L(a, n, k)].$$

Стратегия генерации триплетов

Выбор триплетов

Чтобы гарантировать быструю сходимость, предлагается выбрать триплеты, которые нарушают неравенство

$$\|f(X_a) - f(X_p)\|^2 + \text{margin} < \|(f(X_a) - f(X_n))\|^2.$$

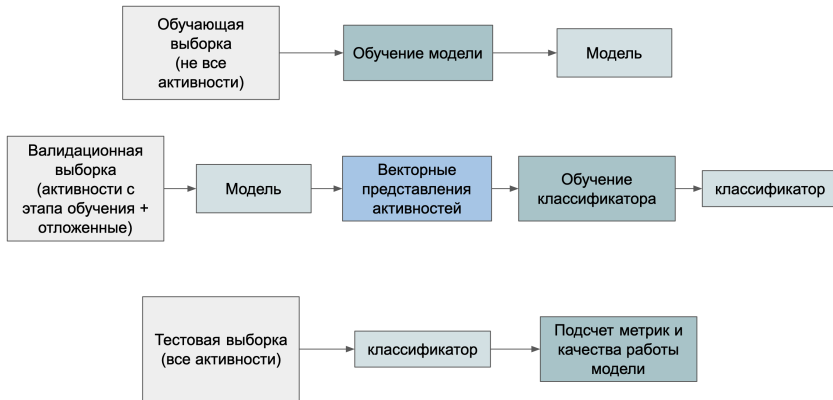
Классификация триплетов

- Сложные положительные: $\arg \max_{X_p} d(f(X_a), f(X_p))$
- Сложные отрицательные: $\arg \min_{X_n} d(f(X_a), f(X_n))$

Предлагаемая стратегия

Во время обучения предлагается для каждого сегмента выбирать топ-к сложных положительных примеров и топ-к сложных отрицательных примеров.

Общий алгоритм обучения и тестирования



В качестве параметрического семейства моделей было выбрано семейство функций, параметризованных нейронной сетью ResNetLSTM.

Вычислительный эксперимент

- Обучение и тестирование проводилось на наборах данных [Crossfit Activities Dataset](#) и [Daily Sports activities](#)
- Размер скользящего окна был выбран длиной 5 секунд, шаг — 1 секунда


| model | $F1$ | $accuracy$ |
|---------------|-----------------|-----------------|
| kNN | 89.19 ± 0.2 | 87.55 ± 0.2 |
| SVM | 88.44 ± 0.2 | 87.20 ± 0.2 |
| Random Forest | 88.69 ± 0.2 | 87.21 ± 0.2 |

Crossfit Activities Dataset


| model | $F1$ | $accuracy$ |
|---------------|-----------------|-----------------|
| kNN | 92.39 ± 0.1 | 93.55 ± 0.1 |
| SVM | 90.34 ± 0.1 | 91.23 ± 0.1 |
| Random Forest | 89.83 ± 0.1 | 89.54 ± 0.1 |

Daily Sports activities

Анализ ошибки



Матрица неточности



TSNE карта векторных представлений активностей

По результатам экспериментов можно сделать вывод, что модель строит репрезентативные векторные представления для классов, которых не было в обучении: приседания и жим гантели вверх (Squats и Pull ups).

- 1 Сформулирована задача построения признакового описания временного ряда сигнала
- 2 Предложен алгоритм обучения, использующий триплет функции потерь и стратегия генерации триплетов во время обучения
- 3 Предложен алгоритм тестирования модели
- 4 Проанализирована полученная модель на датасетах Daily Sports activities и Crossfit Activities Dataset



Lulu Chen, Hong Wei, and James Ferryman.

A survey of human motion analysis using depth imagery.

Pattern Recognition Letters.



Ankita Jain and Vivek Kanhangad.

Human activity classification in smartphones using accelerometer and gyroscope sensors.



Kangjae Lee and Mei-Po Kwan.

Physical activity classification in free-living conditions using smartphone accelerometer data and exploration of predicted results.



Sandeep Pirbhulal, Heye Zhang, and E Alahi.

A novel secure iot-based smart home automation system using a wireless sensor network.



Nishkam Ravi, Nikhil Dandekar, Preetham Mysore, and Michael L Littman.

Activity recognition from accelerometer data.



Pedro Canotilho Ribeiro, José Santos-Victor, and P Lisboa.

Human activity recognition from video: modeling, feature selection and classification architecture.



Jindong Wang, Yiqiang Chen, Shuji Hao, Xiaohui Peng, and Lisha Hu.

Deep learning for sensor-based activity recognition: A survey.