

Классификация движений в однонаправленном компьютерном интерфейсе

Андрей Жуков

Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра «Интеллектуальные системы»

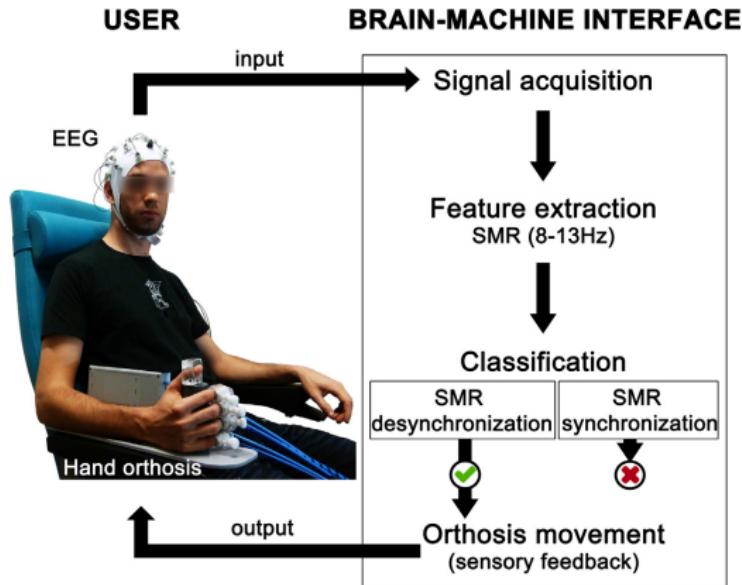
Задачу поставил Е. А. Рябенко
Консультант Е. А. Рябенко
Научный руководитель К. В. Воронцов

Москва
2015г.

Цель исследования

- ① Рассмотреть существующие методы классификации различных видов моторной активности
- ② Предложить оптимальный алгоритм классификации

Нейрокомпьютерные интерфейсы



- Улучшение условий жизни людей, страдающих от паралича
- Усовершенствование техник реабилитации для людей, перенесших инсульт

Использование ЭЭГ для классификации движений возможно, поскольку:

- Двигательная активность сопровождается изменением характера активности нейронов в головном мозге и электромагнитного поля
- Эти изменения происходят в различных областях мозга для различных видов движений

Однако, для корректной классификации необходимо сформировать пространство признаков:

- автоматически агрегирующих информацию об активности
- устойчивых к шуму
- учитывающих нестационарность процессов

Данные представляют собой показания энцефалограммы здоровых пациентов во время исполнения ими моторной активности. Измерения осуществляются с помощью 40 сенсоров с частотой 500Гц.

\mathbf{X} — матрица наблюдений, $\mathbf{X} \rightarrow \mathbf{Y}$,

$\mathbf{Y} = \{0, 1, 2\}$ — три класса: покой, движения левой рукой, движения правой рукой.

$\mathbf{X}_t, t \in \{1, \dots, T\}$ — отрезки наблюдений длиной 1 секунда.

Требуется найти преобразование сигналов $\mathbf{X}_t \rightarrow \mathbf{X}'_t$ и классификатор \mathbf{a} :

$$CV(\mathbf{X}', \mathbf{a}, \mathfrak{D}') \xrightarrow{\max_{\mathbf{a}, \mathbf{x}'}}$$

- ① Фильтрация сигнала (целевой диапазон частот 5-30Гц)
- ② Разбиение сигнала на временные отрезки (1 секунда)
- ③ Формирование признаков:
 - Common Spatial Patterns
 - Principal Component Analysis
 - Оценка коэффициентов матрицы ковариации
- ④ Применение классификатора (SVM-L1 или AdaBoost)

Идея: последовательное выделение компонент, каждая из которых максимизирует ковариацию в остаточной матрице.

Пусть \mathbf{X} — матрица наблюдений.

Тогда найдем

$$\mathbf{w}_{(1)} = \underset{\mathbf{w}}{\operatorname{argmax}} \frac{\|\mathbf{X}\mathbf{w}\|^2}{\|\mathbf{w}\|^2}.$$

В общем случае введем остаточную матрицу

$\hat{\mathbf{X}}_k = \mathbf{X} - \sum_{s=1}^{k-1} \mathbf{X}\mathbf{w}_{(s)}\mathbf{w}_{(s)}^T$, и будем находить k -ую компоненту как

$$\mathbf{w}_{(k)} = \underset{\|\mathbf{w}\|=1}{\operatorname{argmax}} \left\{ \|\hat{\mathbf{X}}_k \mathbf{w}\|^2 \right\}$$

Векторы $\mathbf{w} \in \mathbf{W}$ называются главными компонентами.

Признаковое описание объекта

Коэффициенты матрицы $\mathbf{Z}_i = \mathbf{X}_i \mathbf{W}$.

Формирование признаков: Independent Component Analysis

Идея: определение наблюдений как линейных комбинаций случайных величин.

Предположим, что каждое отдельное наблюдение \mathbf{x}_i является линейной комбинацией n независимых случайных величин:

$$\mathbf{x}_i = \mathbf{A}\mathbf{s}_i.$$

Тогда $\mathbf{X} = \mathbf{AS}$ и $\mathbf{S} = \mathbf{XA}^{-1}$.

Признаковое описание объекта

Коэффициенты матрицы $\mathbf{S}_i = \mathbf{X}_i\mathbf{A}^{-1}$.

Идея: максимизация отношения дисперсий 2x классов.

Пусть $\mathbf{X}_1, \mathbf{X}_2$ — матрицы наблюдений для 2x классов.

Тогда найдем

$$\mathbf{W}^* = \underset{\mathbf{w}}{\operatorname{argmax}} \frac{\|\mathbf{X}_1 \mathbf{W}\|^2}{\|\mathbf{X}_2 \mathbf{W}\|^2}.$$

Векторы $\mathbf{w} \in \mathbf{W}$ называются векторами пространственных фильтров (структур).

Признаконое описание объекта

Коэффициенты матрицы $\mathbf{Z}_i = \mathbf{X}_i \mathbf{W}$.

Формирование признаков: Использование выборочных моментов

Идея: предположим, что наблюдения различных классов — случайные величины из различных многомерных нормальных распределений:

$$y_i = j \implies \mathbf{x}_i \sim \mathcal{N}(\boldsymbol{\mu}^j, \boldsymbol{\Sigma}^j)$$

Тогда:

- Свойства разбиений на временные интервалы в полной мере описываются $\boldsymbol{\mu}^j$ и $\boldsymbol{\Sigma}^j$
- Для разбиений $y_i = j \implies \hat{\boldsymbol{\Sigma}}_i \approx \boldsymbol{\Sigma}^j$ и $\hat{\boldsymbol{\mu}}_i \approx \boldsymbol{\mu}^j$

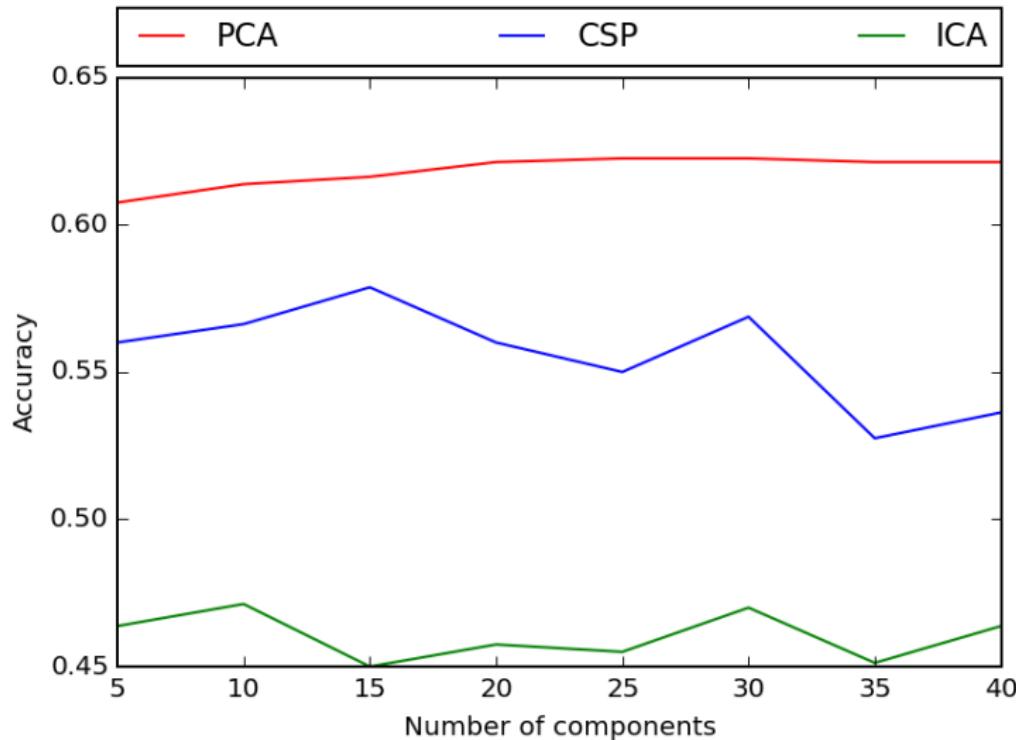
Признаконое описание объекта

Коэффициенты $\hat{\boldsymbol{\mu}}_i$ и $\hat{\boldsymbol{\Sigma}}_i$.

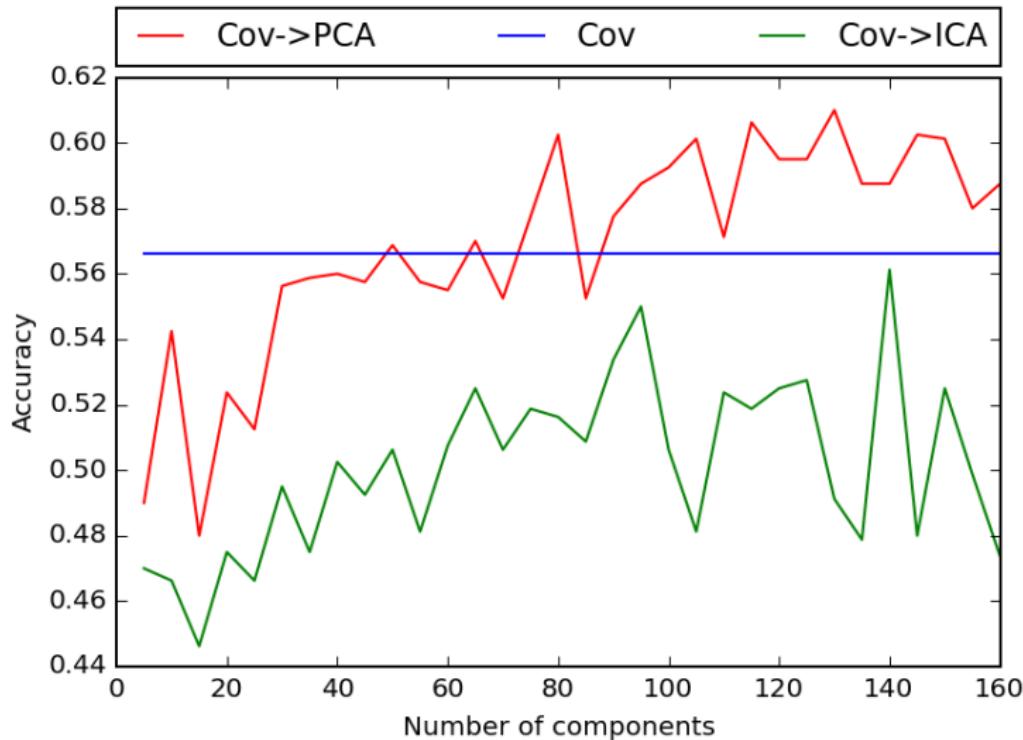
Обозначения моделей

- PCA — Использование метода главных компонент с SVM-классификатором
- ICA — Использование метода независимых компонент с SVM-классификатором
- CSP — Использование метода общих пространственных структур с SVM-классификатором
- AdaCSP — Использование метода общих пространственных структур с AdaBoost-классификатором
- Cov — Использование метода коэффициентов матрицы ковариации с SVM-классификатором
- CovICA — Использование метода коэффициентов матрицы ковариации с последующим применением ICA и SVM-классификатором
- CovPCA — Использование метода коэффициентов матрицы ковариации с последующим применением PCA и SVM-классификатором

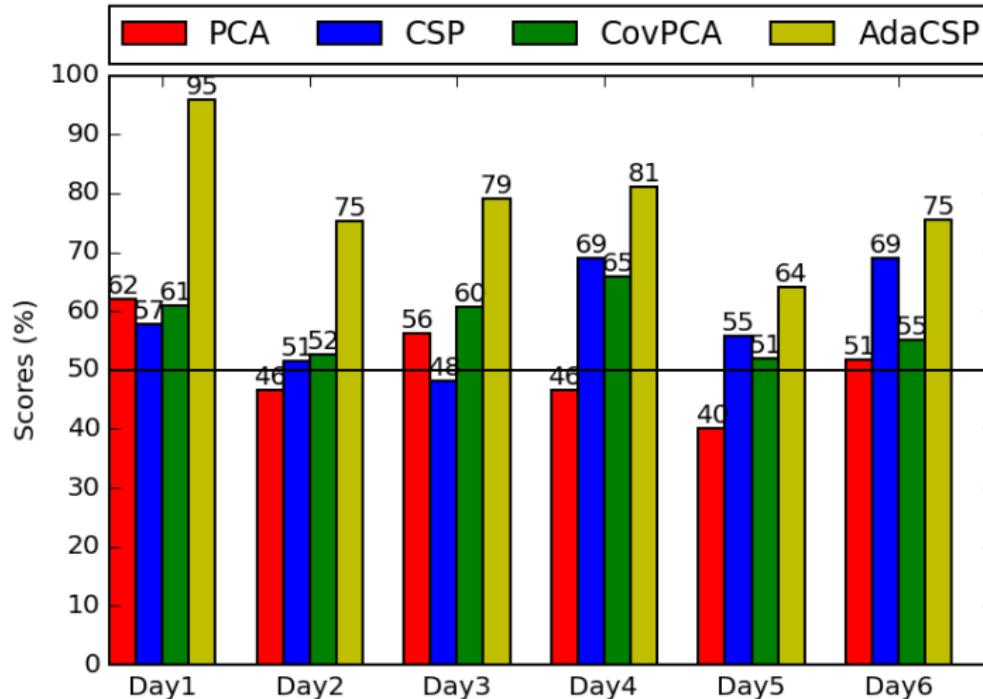
Определение оптимального числа компонент на фильтрованном сигнале



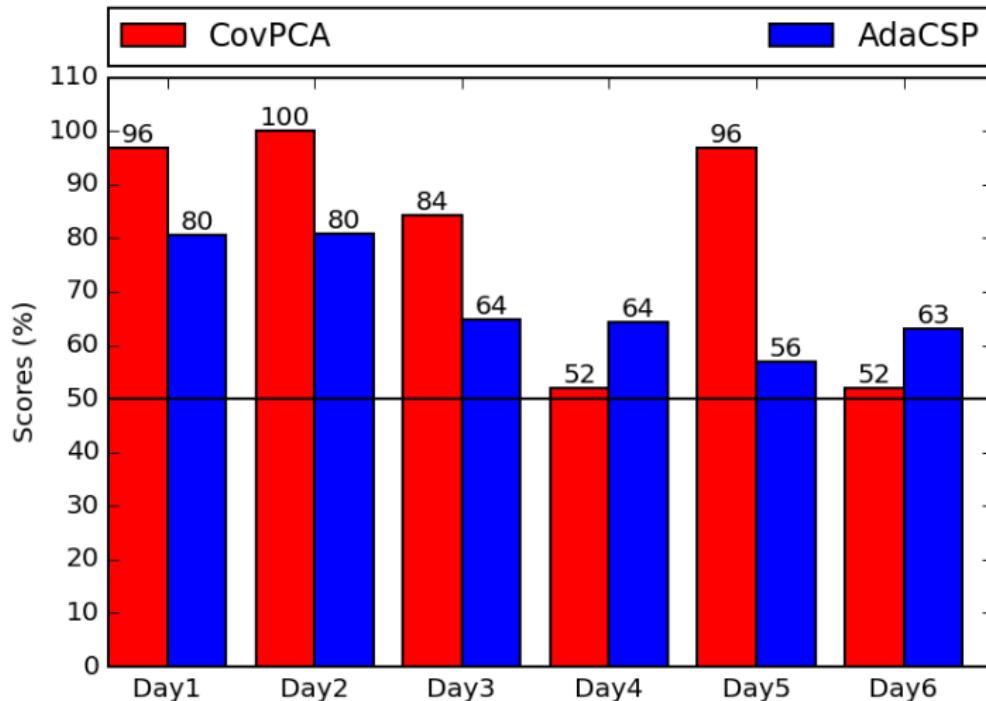
Определение оптимальной модели при использовании выборочных моментов



Проверка обобщающей способности моделей: классификация движений



Проверка обобщающей способности моделей: определение наличия активности



- Получены алгоритмы, дающие достаточно высокую точность классификации видов активности и ее наличия
- Точность классификации варьируется от эксперимента к эксперименту при одних и тех же пациентах.
- Наиболее эффективным для определения типа движения оказался метод пространственных структур с классификатором AdaBoost, обеспечивший среднюю точность 78% по результатам 6 экспериментов.
- Наиболее эффективным для определения наличия движения оказался метод использования коэффициентов ковариации с последующим применением PCA и классификатором SVM, обеспечивший среднюю точность 80% по результатам 6 экспериментов.

Спасибо за внимание!