

Н.В. КАПРАЛОВ, Ж.В. НАГОРНОВА, Н.В. ШЕМЯКИНА
**МЕТОДЫ КЛАССИФИКАЦИИ ЭЭГ-ПАТТЕРНОВ
ВООБРАЖАЕМЫХ ДВИЖЕНИЙ**

Капралов Н.В., Нагорнова Ж.В., Шемякина Н.В. Методы классификации ЭЭГ-паттернов воображаемых движений.

Аннотация. Рассматриваются наиболее перспективные методы классификации электроэнцефалографических сигналов при разработке неинвазивных интерфейсов мозг–компьютер и теоретических подходов для успешной классификации электроэнцефалографических паттернов. Приводится обзор работ, использующих для классификации риманову геометрию, методы глубокого обучения и различные варианты преобработки и кластеризации электроэнцефалографических сигналов, например общего пространственного фильтра. Среди прочих подходов преобработка электроэнцефалографических сигналов с применением общего пространственного фильтра часто используется как в офлайн, так и в онлайн режимах. Согласно исследованиям последних лет сочетание общего пространственного фильтра, линейного дискриминантного анализа, метода опорных векторов и нейронной сети с обратным распространением ошибки позволило достигнуть 91% точности при двухклассовой классификации с обратной связью в виде управления экзоскелетом. Исследований по использованию римановой геометрии в условиях онлайн очень мало, и на данный момент наилучшая точность при двухклассовой классификации составляет 69,3%. При этом в офлайн тестировании средний процент классификации в рассмотренных статьях для подходов с применением общего пространственного фильтра – $77,5 \pm 5,8\%$, сетей глубокого обучения – $81,7 \pm 4,7\%$, римановой геометрии – $90,2 \pm 6,6\%$. За счет нелинейных преобразований методы, основанные на римановой геометрии, а также на применении глубоких нейронных сетей сложной архитектуры, обеспечивают большую точность и способность к извлечению полезной информации из сигнала по сравнению с линейным преобразованием общего пространственного фильтра. Однако в условиях реального времени важна не только точность, но и минимальная временная задержка. Здесь преимущество может быть за подходами с использованием преобразования общего пространственного фильтра и римановой геометрии с временной задержкой менее 500 мс.

Ключевые слова: электроэнцефалографические паттерны, воображаемые движения, риманова геометрия, методы глубокого обучения, искусственные нейронные сети

1. Введение. В последнее десятилетие попытки классификации электроэнцефалографических сигналов (ЭЭГ) для разработки неинвазивных интерфейсов мозг–компьютер (ИМК) исчисляются сотнями. По данным Национального центра биотехнологической информации США [1], более 1700 результатов появляются в ответ на поисковый запрос с ключевыми словами «BCI», «EEG», «Classification».

Основной проблемой является классификация ЭЭГ-сигналов с высокой точностью в режиме реального времени [2-4]. В прикладном аспекте это необходимо, чтобы разработать реабилитационные комплексы для восстановления, например, двигательных функций пациентов после инсульта [5, 6] и черепно-

мозговых травм [7] с вовлечением пациентов в управление внешними устройствами или приложениями с биологической обратной связью, в том числе в игровой форме [8, 9].

Основные сложности при работе с ЭЭГ-сигналом заключаются в низком соотношении сигнал/шум [10], в его существенной вариативности от человека к человеку [11-13] и от сессии к сессии у конкретного пациента [14, 15]. Это обуславливает необходимость делать классификатор либо робастным (устойчивым к изменениям сигнала), либо адаптивным (подстраивающимся под изменения сигнала, в том числе конкретного испытуемого) в условиях небольшого количества данных (длительные процедуры утомительны для пациентов).

Среди подходов к классификации сигналов ЭЭГ можно выделить две группы. Первая группа включает подходы, которые фокусируются на извлечении полезной информации из ЭЭГ-сигнала, построении и проспективном выборе наиболее информативных признаков.

Наиболее частым представителем этого класса является связка преобразования общего пространственного фильтра (Common Spatial Pattern, CSP), вычисления логарифма дисперсии сигнала и применения классификатора на основе линейного дискриминантного анализа (Linear Discriminant Analysis, LDA).

Основным преимуществом подходов этой группы является интерпретация результатов – возможность оценить важность отдельного признака, а затем установить, какой части сигнала соответствует этот признак. Классификаторы на основе римановой геометрии тоже могут быть отнесены к этой группе, однако интерпретация преобразований в многомерном пространстве весьма затруднительна.

Вторая группа включает в себя подходы, в которых используется автоматическое выделение признаков, например свёрточные нейронные сети. Главными достоинствами таких подходов является возможность работы с исходным сигналом и большая способность к обобщению, которая может способствовать устойчивости классификатора к выбросам. Способность к обобщению в целом увеличивается при усложнении архитектуры классификатора, однако также возрастают временные и вычислительные затраты ресурсов на его обучение. В ситуации автоматического извлечения признаков интерпретация результатов сложна, если не удастся восстановить, какую информацию несут в себе извлеченные признаки.

Далее в обзоре будут рассмотрены наиболее часто используемые методы и ряд подходов, способных улучшить точность классификации (decoding accuracy) ЭЭГ-паттернов. Так,

например, в работе [16] было показано, что использование признаков, содержащих информацию об аналитической частоте ЭЭГ-сигнала и показателях функциональной связности (brain connectivity) увеличивает точность классификации или распознавания ЭЭГ-паттернов с 72,9 % до 79,7 %.

В обзоре рассматриваются данные с учетом нескольких различных классов, например:

- воображаемые движения левой и правой рукой;
- состояние покоя и состояние воображения движения любой рукой;
- воображаемые движения левой и правой рукой, двумя ногами или языком.

Данные приводятся в условиях как офлайн, так и онлайн классификации.

2. Задача классификации паттернов ЭЭГ. Формальная постановка задачи классификации паттернов ЭЭГ заключается в следующем: дан набор из N проб $\{X_1, \dots, X_N\}$, для каждой из которых известен класс $y_i \in \{1, \dots, K\}$, где K – количество рассматриваемых классов. Каждая проба является матрицей амплитуд сигнала размера $E \times T$, где E – количество используемых электродов, $T = \Delta t \cdot f_s$ – количество временных отсчетов при длине пробы Δt и частоте дискретизации f_s . Необходимо построить и обучить на имеющихся данных классификатор, способный определять класс для проб в последующих тренировочных сессиях.

Непосредственно перед классификацией проб применяются некоторые методы предобработки сигнала, направленные на улучшение итоговой точности классификации. Можно выделить следующие типичные методы предобработки: аугментация, декомпозиция, пространственная фильтрация, извлечение и выбор признаков.

Поскольку для некоторых классификаторов точность сильно зависит от количества имеющихся данных, в некоторых случаях прибегают к *аугментации* – искусственному увеличению объёма имеющихся данных. Например, с помощью метода скользящего окна можно вместо одной пробы извлечь несколько проб с перекрытием [17], при этом новые пробы будут относиться к тому же классу, что и исходная. Также в настоящее время исследуются возможности использования генеративно-сопоставительных сетей (Generative Adversarial Network, GAN) [18, 19], которые позволяют генерировать сигналы, похожие на ЭЭГ как во временной, так и в частотной областях.

Декомпозиция заключается в разбиении исходного сигнала на отдельные компоненты, среди которых возможно выбрать наиболее специфичные для конкретного испытуемого. Таким образом, осуществляется индивидуальная подстройка классификатора. К методам декомпозиции можно отнести полосовую фильтрацию, использованную в [20], а также различные методы выделения мод, в частности Empirical Mode Decomposition (EMD) [21] и Local Characteristic-Scale Decomposition (LCD) [16].

Пространственная фильтрация используется для повышения соотношения сигнал/шум. Так, в [22] показано, что использование специальных референтов («нулевых» электродов/отведений сравнения) может существенно влиять на точность классификации и чувствительность к артефактам. Наиболее используемым методом пространственной фильтрации является преобразование Common Spatial Pattern (CSP) [23-25], формирующее линейные комбинации значений сигнала отдельных каналов, позволяющие наилучшим образом различить два класса.

В качестве входных данных любому методу классификации необходимо предоставить набор чисел, называемых *признаками*, при этом для успешной классификации необходимо, чтобы признаки в совокупности позволяли отличить пробы, относящиеся к разным классам. В качестве признаков могут быть использованы исходные матрицы X_i , однако значение амплитуды сигнала в конкретный момент времени не является стабильным признаком.

В связи с этим часто применяется процедура *выделения признаков*, в ходе которой на основе исходного сигнала рассчитываются более стабильные признаки. При выделении признаков могут быть рассмотрены временная область, частотная область или обе области сразу. Во временной области используются коэффициенты авторегрессионной модели [22, 26], ковариационные матрицы [27], а также логарифм дисперсии сигнала [20, 24]. Для учета информации о частотной области используются мощность в полосе [28], а также вейвлет-коэффициенты [28].

После выделения признаков производится *выбор признаков*, наилучшим образом позволяющих предсказать класс проб. Для этого используются отбор на основе взаимной информации значений признака и целевой переменной (класса) [29], метод роя частиц [30] и кластеризация признаков [31]. Для решения задачи классификации с использованием выбранных признаков используются методы машинного обучения.

3. Методы классификации ЭЭГ паттернов. Методы машинного обучения, применимые для классификации ЭЭГ-

паттернов, можно разбить на несколько категорий в соответствии с обзорами [10, 32]. Ниже приводится список методов, разбитых на категории со ссылками на работы, в которых был использован соответствующий метод:

- методы построения гиперплоскости, разделяющей классы: линейный дискриминантный анализ (Linear Discriminant Analysis, LDA) [4], метод опорных векторов (Support Vector Machine, SVM) [2];

- методы, основанные на вычислении близости между объектами: метод ближайших соседей [33], Minimum Riemannian Distance to Mean (MRDM) [27];

- вероятностные методы: байесовский классификатор [34], марковские модели [35];

- деревья решений [33];

- глубинные нейронные сети [17, 36, 37].

В следующих разделах подробно обсуждаются наиболее популярные подходы, использующие CSP, концепцию римановой геометрии и глубинные нейронные сети.

В таблице 1 представлено краткое сравнение часто используемых подходов, составленное на основе описаний методов классификации, которые используются в рассматриваемых в обзоре работах.

Таблица 1. Сравнение рассматриваемых в обзоре методов

Критерии	Подходы		
	CSP	Риманова геометрия	Глубинные нейронные сети
Ключевые особенности	Простота интерпретации результата	Сочетание робастности и адаптивности	Автоматическое извлечение признаков
Входные данные	Ковариационные матрицы проб	Ковариационные матрицы проб	Исходный сигнал и/или извлеченные признаки
Вычислительная сложность	Невелика, зависит от числа используемых каналов	Невелика, зависит от числа используемых каналов	Может быть велика при использовании сложной архитектуры
Графическое представление признаков и/или результата	Топографические карты	Визуализация многомерного пространства проб с использованием методов снижения размерности	Топографические карты

4. Преобразование CSP. Это преобразование, целью которого является получение пространственных фильтров, позволяющих наилучшим образом разделить классы. Метод основан на одновременной диагонализации ковариационных матриц, соответствующих разным классам [23]. Впервые этот метод был использован для классификации сигналов ЭЭГ, связанных с движениями, в [24, 25]. Алгоритм CSP включает в себя следующие шаги:

1. Для каждой пробы необходимо вычислить ковариационную матрицу:

$$C_i = \frac{1}{T-1} \cdot (X_i - E[X_i]) \cdot (X_i - E[X_i])^T. \quad (1)$$

2. Для каждого класса рассчитываются средние ковариационные матрицы \overline{C}_l и \overline{C}_r . Из усредненных матриц составляется объединенная матрица, которая может быть спектрально разложена:

$$C_c = \overline{C}_l + \overline{C}_r = U_c \lambda_c U_c^T.$$

3. Вычисляется матрица для отбеливания (whitening) объединенной матрицы:

$$P = \sqrt{\lambda_c^{-1}} U_c.$$

В результате отбеливания все собственные числа матрицы $PC_c P^T$ становятся равными 1.

4. Отбеливание с использованием матрицы P применяется к средним ковариационным матрицам классов:

$$S_l = PC_l P^T; S_r = PC_r P^T.$$

5. Матрицы S_l и S_r по построению имеют одни и те же собственные векторы, то есть их компоненты одним и тем же образом выражаются через изначальные сигналы, при этом для собственных чисел верно следующее соотношение:

$$S_l = B \overline{\lambda}_l B^T; S_r = B \overline{\lambda}_r B^T; \overline{\lambda}_l + \overline{\lambda}_r = I.$$

Поскольку сумма двух соответствующих собственных чисел будет равна 1, собственный вектор, соответствующий наибольшему

собственному числу матрицы S_l , будет соответствовать наименьшему собственному числу матрицы S_r , и наоборот. Проекция отбеленной ЭЭГ на несколько первых и последних собственных векторов B , соответствующих наибольшим значениям $\bar{\lambda}_l$ и $\bar{\lambda}_r$, будут оптимальны для классификации.

6. Итоговая матрица преобразования W формируется следующим образом:

$$Z_i = WX_i = (B^T P)^T X_i.$$

После применения преобразования CSP в качестве признака для классификации используется логарифм нормализованной дисперсии n наилучших компонент:

$$f_p = \log \left(\frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)} \right).$$

Взятие логарифма используется для приближения распределения значений признака к нормальному.

Для интерпретации результатов преобразования используются столбцы матрицы W^{-1} .

На рисунке 1 представлены топографические карты паттернов активации с использованием CSP, позволяющие наилучшим образом различить воображаемые движения левой и правой рук. Для вычисления были использованы данные испытуемого S001 набора данных EEGBCI [38], а также реализация алгоритма и визуализации из библиотеки MNE-Python [39].

Преобразование CSP предназначено для разделения двух классов, однако оно также может быть обобщено на большее количество классов. В работе [40] наилучшую точность предсказания четырех классов принесла стратегия обобщения «один против остальных» (One vs Rest). Согласно этой стратегии для каждого класса применялось преобразование CSP, наилучшим образом отличающее пробы этого класса от проб всех остальных классов.

Точность классификации сильно зависит от индивидуальных особенностей человека. В связи с этим можно рассмотреть набор полосовых фильтров (Filter Bank) и для сигнала ЭЭГ, отфильтрованного в каждой из полос, извлечь признаки после

преобразования CSP. Далее можно выбрать наиболее информативные для каждого испытуемого признаки, таким образом обеспечивая индивидуальную подстройку классификатора под человека. Комбинация CSP и полосовых фильтров получила название FBCSP, и этот алгоритм показал наилучший результат в рамках BCI Competition IV для классификации воображаемых движений [40].



Рис. 1. Топографические карты, соответствующие паттернам активации, полученным в результате применения алгоритма CSP для классификации воображаемых движений левой и правой рук (сжатие кисти)

5. Методы классификации, основанные на концепции римановой геометрии. Концепция римановой геометрии предполагает рассмотрение метрического пространства (риманова многообразия), которому принадлежат ковариационные матрицы проб. Эта концепция была впервые использована для классификации ЭЭГ в работах [27]. Для определения близости проб вводится метрика расстояния между ковариационными матрицами этих проб, определяемая выражением (2):

$$\delta_R(C_1, C_2) = \left\| \log(C_1^{-1}C_2) \right\|_F = \left[\sum_{i=1}^N \log^2 \lambda_i \right]^{1/2}, \quad (2)$$

где $\lambda_i, i = 1 \dots N$ – собственные числа матрицы $C_1^{-1}C_2$.

Одним из базовых методов классификации является метод ближайших соседей, в основе которого лежит предположение о том, что близкие объекты должны относиться к одному и тому же классу. Алгоритм Minimum Riemannian Distance to Mean (MRDM) [27] является обобщением метода ближайших соседей для риманова многообразия, используя (2) для оценки близости объектов, то есть проб. Алгоритм включает следующие шаги:

1. Вычислить ковариационные матрицы проб из обучающей выборки согласно выражению (1).

2. Вычислить ковариационную матрицу C_t для пробы, класс которой необходимо определить.

3. Для всех классов $k = 1 \dots K$ вычислить геометрическое среднее ковариационных матриц проб $C_1^k, \dots, C_{N_k}^k$, соответствующих этому классу:

$$C^k(C_1^k, \dots, C_{N_k}^k) = \arg \min_C \sum_{i=1}^N \delta_R^2(C, C_i^k). \quad (3)$$

Геометрическое среднее набора ковариационных матриц может быть подсчитано в соответствии с подходом Фреше с помощью итерационного алгоритма [41].

4. Вычислить риманово расстояние от матрицы пробы, класс которой неизвестен, до средних матриц каждого из классов. Присвоить новой пробе класс, расстояние до матрицы которого оказалось наименьшим:

$$k = \arg \min_k \delta_R(C_t, C^k).$$

Альтернативным способом применения концепции риманова пространства является использование касательного пространства (Tangent Space, TS) [42]. Многие эффективные методы машинного обучения (LDA, SVM, нейронные сети) не могут быть использованы во введенном метрическом пространстве. Поскольку ковариационные матрицы являются симметричными и положительно определенными, введенное пространство локально похоже, то есть может быть отображено на касательное евклидово пространство.

Касательное пространство может быть построено в любой точке риманова многообразия, при этом векторы на гиперплоскости, соответствующие ковариационным матрицам, будут определяться выражением (4):

$$S_i = \text{Log}_C(C_i) = C^{1/2} \log\left(C^{-1/2} C_i C^{-1/2}\right) C^{1/2}, \quad (4)$$

где C – точка (ковариационная матрица), в которой строится касательное пространство; \log – матричный логарифм.

Таким образом, алгоритм TS включает следующие шаги:

1. Вычислить ковариационные матрицы проб из обучающей выборки согласно (1).

2. Вычислить риманово среднее ковариационных матриц всех проб, используя (3).

3. Спроецировать ковариационные матрицы всех проб на касательное пространство в точке риманова среднего согласно (4).

4. Для полученных проекций можно применять все популярные методы машинного обучения, в частности LDA и SVM.

Для визуализации можно использовать отображение tSNE, позволяющее спроецировать точки, находящиеся в многомерном пространстве, на 2D плоскость. Также в работе [43] более наглядно описываются манипуляции над ковариационными матрицами в римановом многообразии.

6. Глубинные нейронные сети. Глубинные нейронные сети в зависимости от используемой архитектуры могут решать как задачу классификации, так и задачу выделения признаков. Полносвязные сети прямого распространения [44] подходят для классификации, а *автоэнкодеры* [45] – для автоматического выделения признаков за счет поиска скрытого представления. В то же время *сверточные сети* [46] благодаря комбинации сверточных и полносвязных слоев, отвечающих за выделение признаков и классификацию, решают обе задачи, благодаря чему на вход сверточной сети подается исходный сигнал, что лишает необходимости процедуру ручного выделения признаков. *Рекуррентные* сети с использованием LSTM-ячеек [47] позволяют работать с последовательностями, поддерживая контекст, благодаря чему активно используются для машинного перевода и могут быть применены в обработке сигналов.

Среди рассматриваемых в обзоре работ наиболее часто были использованы свёрточные нейронные сети (Convolutional Neural Networks, CNN). Сверточная нейронная сеть – один из видов архитектуры искусственной нейронной сети, предложенный Яном ЛеКуном [46] для эффективного распознавания образов в изображениях. В отличие от обычной ИНС, в сверточной нейронной сети еще есть сверточные слои, а также слои пулинга. Комбинации подобных слоев позволяют эффективно извлекать признаки из входных данных, существенно уменьшая количество обрабатываемой информации, при этом сохраняя специфичную для задачи классификации информацию.

При работе с сигналами ЭЭГ на вход сверточной сети могут быть поданы спектрограммы, в таком случае задача сводится к классификации изображений. Альтернативным вариантом входных

данных является исходной сигнал. В таком случае часто используется архитектура, являющаяся адаптацией метода FBCSP. В работе [17] описывается подобная архитектура ShallowNet, представленная на рисунке 2. Ниже описаны все используемые слои и их предназначение:

1. Выполняется свертка во времени с использованием ядра 1×25 с целью выделения характерных пиков в сигнале.
2. Производится свертка по всем электродам, этот этап аналогичен пространственной фильтрации в алгоритме FBCSP.
3. Все значения матрицы поэлементно возводятся в квадрат.
4. Для каждого окна 1×75 производится пулинг по времени: берется среднее значение элементов в окне.
5. От каждого элемента берется его натуральный логарифм. Комбинация шагов 3-5 эквивалентна вычислению логарифма дисперсии сигнала в алгоритме FBCSP.
6. Задачу классификации для полученных после пулинга признаков решает комбинация из полносвязного и softmax слоев.




Рис. 2. Архитектура сверточной сети ShallowNet из работы [17]

Главным недостатком методов глубинного обучения является зависимость от количества имеющихся данных – чем больше данных, чем лучше обобщение. В настоящее время для решения этой проблемы используются методы аугментации, уже упомянутые ранее.

7. Сравнение методов классификации. Сравнение производилось на наборе данных BCI Competition IV/2a [48]. В исследовании участвовало 9 здоровых испытуемых, выполнявших 4 типа воображаемых движений: левой и правой рукой, обеими ногами сразу, языком. При регистрации ЭЭГ были использованы 22 отведения (Fz, Fc3, Fc1, Fc2, Fc4, C5, C3, C1, Cz, C2, C4, C6, Cp3, Cp1, Cpz, Cp2, Cp4, P1, Pz, P2, Poz), длительность пробы составила 4 с [48]. В таблице 2 представлены работы, в которых описаны методы, дающие наибольшую точность классификации для набора данных BCI Competition IV/2a, а также работы, стоящие в основе рассматриваемых в обзоре подходов.

В рассматриваемых работах были использованы два метода оценки точности классификации – контроль на отложенных данных (hold-out) и кросс-валидация. При «hold-out» часть данных (обычно 20-30%) выбирается в качестве тестовой выборки и никак не используется при обучении и настройке параметров классификатора. При кросс-валидации данные делятся на заранее выбранное (часто используемые значения – 5, 10) число частей (folds), и каждая часть по очереди выступает в качестве тестовой выборки, в то время как все остальные в сумме образуют тренировочную выборку. Финальная оценка точности является средним значением точностей, полученных на каждой части по отдельности. Для компенсации случайных эффектов (разбиение данных, инициализация моделей машинного обучения) и получения более стабильных оценок также используется усреднение нескольких результатов.

Использование того или иного метода может влиять на итоговый результат. Например, если регистрация данных проходила посессионно в течение нескольких дней, то часто наблюдается существенная разница между записями первых и последних сессий. В таком случае возникает необходимость адаптации модели к состоянию испытуемого в первый и последний дни. Эффект адаптации можно оценить, если обучать модель на нескольких первых сессиях, а тестировать – на последних. Однако при использовании кросс-валидации возможно смешивание проб из разных сессий, что может нарушить объективность оценки способности модели к адаптации.

Таблица 2. Сравнение точности классификации с использованием разных подходов для набора данных VCI Competition IV/2a (4 класса, воображение движений левой и правой рукой, обеими ногами, языком)

	Сигнал	Классификация	Результат
Статья	а) анализируемый диапазон частот; б) длительность окна анализа	а) предобработка; б) используемые признаки; в) метод классификации; г) метод выбора признаков	а) точность; б) каппа; в) метод оценки
[49]	а) 4-38 Гц; б) 0-4 с, эпоха анализа 0,8 с	а) 16 фильтров, ширина полосы 4 Гц, перекрытие 2 Гц; б) логарифм дисперсии сигнала; в) CNN, LSTM; г) –	а) 83; б) 0,8; в) hold-out, усреднение 10 реализаций

Продолжение таблицы 2

[16]	а) 8-30 Гц; б) не указана	а) LCD + преобразование Гильберта, CSP; б) аналитическая частота, логарифм дисперсии сигнала, Brain Network Features; в) SRDA; г) Multi-Cluster Feature Selection	а) 79,7; б) 0,73; в) 10-fold CV
[50]	а) не указан; б) (-0,5)-4 с	а) аугментация путем добавления шума; б) вектор амплитуд сигнала; в) CNN; г) –	а) 74,6; б) 0,659; в) не указан
[51]	а) 4-40 Гц; б) 0,5-2,5 с	а) FBCSP; б) огибающая сигнала; в) CNN (Channel-wise Convolution with Channel Mixing); г) –	а) 74,46; б) – в) hold-out, усреднение 50 реализаций
		а) FBCSP; б) огибающая сигнала; в) CNN (Channel-wise CNN); г) –	а) 73,07; б) – в) hold-out, усреднение 50 реализаций
[36]	а) не указан; б) 0,5-2,5 с	а) Exponential Weighted Moving Average; б) вектор амплитуд сигнала; в) CNN (EEGNet); г) –	а) 73,7; б) – в) 4-fold CV
[17]	а) 4-38 Гц; б) 0,5-4 с, эпоха анализа 2 с	а) Exponential Weighted Moving Average; б) вектор амплитуд сигнала; в) CNN (Shallow ConvNet); г) –	а) 73,7; б) – в) не указан
[52]	а) 8-30 Гц; б) 1-3 с	а) FBCSP; б) вектор амплитуд сигнала; в) RNN (GRU-RNN); г) –	а) 73,56; б) – в) не указан
		а) FBCSP; б) вектор амплитуд сигнала; в) RNN (LSTM-RNN); г) –	а) 72,58; б) – в) не указан

Продолжение таблицы 2

[17]	а) 4-38 Гц; б) 0,5-4 с, эпоха анализа 2 с	а) Exponential Weighted Moving Average; б) вектор амплитуд сигнала; в) CNN (Deep ConvNet); г) –	а) 70,9; б) – в) не указан
[33]	а) 8-30 Гц; б) 0,5-2,5 с	а) переход к TS, GDA для уменьшения размерности; б) проекции ковариационных матриц в TS; в) ансамбль kNN-классификаторов; г) Mutual Information	а) 70,525; б) 0,607; в) 10-fold CV
[53]	а) 8-30 Гц; б) 1,75-3,75 с	а) переход к TSSM (Tangent Space of Sub-Manifold) ; б) проекции ковариационных матриц в TSSM; в) LDA; г) –	а) 69,475; б) 0,593; в) 30-fold CV
[20]	а) 4-40 Гц; б) 0,5-2,5 с	а) FBCSP; б) логарифм дисперсии сигнала; в) Naïve Bayesian Parzen Window; г) Mutual Information	а) 67,75; б) 0,57; в) hold-out
[27]	а) 8-30 Гц; б) 0,5-2,5 с	а) – б) ковариационные матрицы, переход к TS; в) LDA; г) ANOVA, FDR	а) 67,525; б) 0,567; в) hold-out

Примечание 1: (FB)CSP – (Filter Bank) Common Spatial Pattern, ConvNet, CNN – Convolutional Neural Network, LSTM – Long Short-Term Memory, LCD – Local Characteristic-Scale Decomposition, SRDA – Spectral Regression Discriminant Analysis, LDA – Linear Discriminant Analysis, TS – Tangent Space, CV – кросс-валидация,

Примечание 2: в методе hold-out используется тестовая выборка, в методе N-fold CV данные разбиваются на N частей, и поочередно каждая часть служит в качестве тестовой выборки, а все остальные части – в качестве тренировочной выборки.

Примечание 3: для сравнения классификаторов используется каппа – величина, которая показывает, насколько полученная точность p

превышает p_e – вероятность случайно предсказать класс (при сбалансированных классах $p_e = 1/K$):

$$\kappa = \frac{p - p_e}{1 - p_e}.$$

Проведенный сравнительный анализ результатов офлайн тестирования на наборе данных «BCI соревнования» (4 класса) показал, что наилучшая точность (83,7 %) достигалась с использованием нейронной сети глубокого обучения со свёрточными слоями и LSTM-ячейками, обученной на значениях логарифма дисперсии сигнала, которые были получены после преобразования FBCSP [49]. Сопоставимый уровень точности (79,7%) был получен с использованием признаков разной природы и дискриминатного анализа на основе спектральной регрессии (Spectral Regression Discriminant Analysis) [16]. Для классификации были использованы: 1) значения аналитической частоты мод, выделенных с помощью преобразования LCD; 2) значения логарифма дисперсии сигнала, полученного после преобразования CSP; 3) значения нескольких характеристик графа функциональной коннективности (brain connectivity) – степени вершин, средней длины кратчайшего пути и др. В графе функциональной коннективности вершинами являются отведения ЭЭГ, и два отведения соединены ребром, если значение коэффициента корреляции сигналов с этих отведений превышает пороговое значение (в [16] в качестве порогового значения было использовано значение 0.84).

В ряде других работ [17, 36, 50, 51, 52] точность свыше 70 % удалось получить при использовании сверточных и рекуррентных сетей различной архитектуры – EEGNet, Deep/Shallow ConvNet и других.

8. Применение Common Spatial Pattern для классификации ЭЭГ сигналов. Согласно данным, приведенным в таблице 3, исследования с применением CSP в офлайн режиме достаточно многочисленны. С использованием данного подхода к преобразованию сигнала точность классификации колеблется между 75-84 % при двухклассовой офлайн классификации. При этом лучший результат (точность классификации – 84,2 %) достигнут при

варьировании данных ВСИ соревнования, индивидуальном выборе частотной полосы классификации, использовании линейного дискриминантного анализа и данных с большого количества электродов (118) [4]. По сравнению с другими методами CSP преобразование часто используется в онлайн классификации при управлении экзоскелетом в качестве обратной связи (табл. 4), точность двухклассовой классификации может достигать 87-91 % при выборе индивидуальных частот анализа, комбинации LDA, SVM и нейросети (BPNN) [2].

Таблица 3. Применение CSP в режиме офлайн

	Данные	Классификация	Результат
Статья	а) число классов, воображаемые движения б) количество анализируемых ЭЭГ отведений; в) анализируемый диапазон частот г) длительность пробы	а) предобработка; б) используемые признаки; в) метод классификации; г) метод выбора признаков	а) точность; б) каппа; в) метод оценки
[2]	а) 2, Л./П. руки; б) 28; в) 8-30 Гц; г) 5 с, анализируемый сигнал 1-4 с	а) индивидуальный подбор полосы шириной 4 Гц: 8-12, 12-16, 14-18 или 18-22 Гц на основе ERD/ERS, затем FBCSP;	а) 76,38; б) – в) hold-out
	а) 2, реальные движения Л./П. руками; б) 28; в) 8-30 Гц; г) 5 с, анализируемый сигнал 1-4 с	б) логарифм дисперсии сигнала; в) LDA, SVM, BPNN; г) –	а) 79,19; б) – в) hold-out
[4]	а) 2, Л./П. руки; б) 22 (BCI Comp. IV/2a) ; в) 0,5-100; г) 4 с	а) индивидуальный подбор частотной полосы, WOLA, CSP; б) логарифм дисперсии сигнала; в) LDA; г)	а) 78,85; б) – в) hold-out
	а) 2, Л./П. руки; б) 118 (BCI Comp. III/4a); в) 1-50; г) 3,5 с		а) 84,28; б) – в) hold-out
	а) 2, Л./П. руки; б) 60 (BCI Comp. III/3a) ; в) 0,05-200; г) 4 с		а) 67,28; б) – в) hold-out

Продолжение таблицы 3

[28]	а) 2, покой, хождение б) 32 в) 8-13, 13-30 Гц г) 5 с	а) CSP, вейвлет-преобразование, Multi-Level Multi-View Deep Polynomial Network (MMDPN); б) логарифм дисперсии сигнала, PSD, коэффициенты вейвлетов; в) LDA; г)	а) 81,81; б) – в) hold-out, усреднение 10 реализаций
------	---	---	--

Примечание 1: (FB)CSP – (Filter Bank) Common Spatial Pattern, LDA – Linear Discriminant Analysis, SVM – Support Vector Machine, BPNN – Back Propagation Neural Network, MMDPN – Multi-Level Multi-View Deep Polynomial Network, PSD – Power Spectral Density, ERD/ERS – Event-Related Desynchronization/Synchronization, WOLA – Weight Overlap-Add.

Примечание 2: в методе hold-out используется тестовая выборка, в метода N-fold CV данные разбиваются на N частей, и поочередно каждая часть служит в качестве тестовой выборки, а все остальные части – в качестве тренировочной выборки.

Таблица 4. Применение CSP в режиме онлайн

	Данные	Классификация	Эксперимент
Статья	а) число классов, воображаемые движения; б) количество ЭЭГ отведений при анализе; в) анализируемый диапазон частот; г) длительность пробы	а) предобработка; б) используемые признаки; в) метод классификации; г) метод выбора признаков	а) обратная связь; б) точность (%); в) метод оценки
[16]	а) 4, Л./П. руки, язык, Л.+П. ноги; б) 16 (Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5 и T6); в) 8-30 Гц; г) 4 с, анализируемый интервал 2,5-3,5 с	а) LCD + преобразование Гильберта, CSP; б) аналитическая частота, логарифм дисперсии сигнала, Brain Network Features; в) SRDA; г) Multi-Cluster Feature Selection	а) управление роботом NAO: перемещение 2D; б) – в) –

Продолжение таблицы 4

[54]	а) 2, Л./П. руки; б) в разных сессиях 9 (F3, Fz, F4, C3, Cz, C4, P3, Pz, P4) или 40; в) 8-26 Гц г) 6 с	а) CSP; б) логарифм дисперсии сигнала; в) LDA; г) –	а) управление курсором в парадигме BC12000; б) 75; в) hold-out
[29]	а) 2, покой, движение Л. или П. рукой; б) 24; в) 4-40 Гц; г) не указана	а) FBCSP; б) логарифм дисперсии сигнала; в) LDA; г) Mutual Information	а) – б) 74,53; в) hold-out
[4]	а) 2, Л./П. руки; б) 22; в) не указан; г) не указана;	а) индивидуальный подбор частотной полосы, WOLA, CSP; б) логарифм дисперсии сигнала; в) LDA; г) –	а) – б) 80,25; в) hold-out;
[2]	а) 2, Л./П. руки; б) 28; в) 8-30 Гц; г) 5 с, анализируемый сигнал 1-4 с	а) индивидуальный подбор полосы шириной 4 Гц: 8-12, 12-16, 14-18 или 18-22 Гц на основе ERD/ERS, затем FBCSP; б) логарифм дисперсии сигнала; в) LDA, SVM, BPNN; г) –	а) управление экзоскелетом: сгибание и разгибание локтя; б) 87,93; в) hold-out
	а) 2, реальные движения Л. рукой или Л.+П. ногами; б) 28; в) 8-30 Гц; г) 5 с, анализируемый сигнал 1-4 с		а) управление экзоскелетом: сгибание и разгибание; б) 91,32; в) hold-out

Примечание 1: LCD – Local Characteristic-Scale Decomposition, CSP – Common Spatial Pattern, LDA – Linear Discriminant Analysis, SRDA – Spectral Regression Discriminant Analysis, SVM – Support Vector Machine, BPNN – Back Propagation Neural Network.

Примечание 2: в методе hold-out используется тестовая выборка, в методе N-fold CV данные разбиваются на N частей, и поочередно каждая часть служит в качестве тестовой выборки, а все остальные части – в качестве тренировочной выборки.

Согласно приведенным данным исследования с применением CSP в офлайн режиме достаточно многочисленны. С использованием данного подхода к преобразованию сигнала точность классификации колеблется между 75-84% при двухклассовой офлайн классификации. При этом лучший результат (точность классификации – 84,2%) достигнут при варьировании данных ВСІ соревнования, индивидуальном выборе частотной полосы классификации, использовании линейного дискриминантного анализа и данных с большого количества электродов (118) [4]. По сравнению с другими методами CSP преобразование часто используется в онлайн классификации при управлении экзоскелетом в качестве обратной связи, точность двухклассовой классификации может достигать 87-91% при выборе индивидуальных частот анализа, комбинации LDA, SVM и нейросети (BPNN) [2].

9. Применение классификаторов на основе концепции римановой геометрии для классификации ЭЭГ сигналов. При использовании офлайн тестирования, классификаторы на основе римановой геометрии дают лучшую точность распознавания, по сравнению с использованием CSP. По данным из таблиц 3 и 5 при классификации на 2 класса наблюдается значимое различие точности, $p < 0.05$ по критерию Манна – Уитни, в пользу классификаторов на основе римановой геометрии: $90,2 \pm 6,6\%$ по сравнению с $77,5 \pm 5,8\%$ при использовании CSP. Однако при переходе к классификации онлайн (табл. 6) точность классификатора на основе римановой геометрии снижалась до 69,3% (по сравнению с режимом офлайн). Работы, адаптирующие классификаторы на основе концепции римановой геометрии к применению в режиме реального времени, еще только начинают появляться и можно ожидать их дальнейшего развития. Любопытно, что точность классификации на основе римановой геометрии (в режиме офлайн, табл. 5) не зависела от количества использованных электродов (минимальное используемое количество электродов – 14). Наибольшая точность – более 96% при классификации на 2 класса – наблюдалась при выборе специфичной для испытуемого частотной полосы на основе спектрограмм, переходе в касательное пространство и использовании классификатора LDA [31, 56]. В данных исследованиях классифицируемые состояния были либо покой, либо движение ногами. При классификации движений рук (Л./П. рука) точность классификации варьировала между 80-90%.

Таблица 5. Применение римановой геометрии в режиме офлайн

Статья	Данные	Классификация	Результат
	а) число классов, воображаемые движения; б) количество ЭЭГ отведений при анализе; в) анализируемый диапазон частот; г) длительность пробы	а) предобработка; б) используемые признаки; в) метод классификации; г) метод выбора признаков	а) точность; б) каппа; в) метод оценки
[33]	а) 4, Л./П. руки, язык, Л.+П. ноги; б) 64 (BCI Comp. III/3a) ; в) 0,05-200 Гц; г) 4 с	а) переход к TS, GDA для уменьшения размерности; б) проекции ковариационных матриц в TS; в) ансамбль kNN-классификаторов; г) Mutual Information	а) 82,78 б) – в) 10-fold CV
	а) 3 – сгибание, разгибание и отведение плеча в) 14 (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 и AF4) в) не указан г) 3 с		а) 85 б) – в) 10-fold CV
[55]	а) 2, П. рука, Л. нога; б) 118 (BCI Comp. III/4a); в) 7-30 Гц; г) анализируемый сигнал 0,5-2,5 с	а) CSP; б) ковариационные матрицы; в) FGMRDM; г) -	а) 86,13; б) 0,72; в) hold-out
	а) 2, Л./П. руки; б) 60; в) 7-30 Гц; г) анализируемый сигнал 0,5-2,5 с		а) 92,2; б) – в) hold-out
	а) 2, Л./П. руки; б) 22; в) 7-30 Гц; г) анализируемый сигнал 0,5-2,5 с		а) 81,2; б) – в) hold-out

Продолжение таблицы 5

[31]	<p>а) 2, покой, педалирование б) 19 (Fz, FC3, FC1, FCz, FC2, FC4, C5, C3, C1, Cz, C2, C4, C6, CP3, CP1, CPz, CP2, CP4 и Pz) в) 8-30 Гц; г) 5 с, анализируемый сигнал 0,5-5 с, эпоха анализа 0,5 с</p>	<p>а) выбор специфичной для испытуемого частотной полосы на основе спектрограмм; б) ковариационные матрицы, переход к TS Римана; в) LDA; г) Fast Neighborhood Component Analysis</p>	<p>а) 96,43; б) 0,9285; в) hold-out</p>
[56]	<p>а) 2, покой, педалирование; б) 19 (Fz, FC3, FC1, FCz, FC2, FC4, C5, C3, C1, Cz, C2, C4, C6, CP3, CP1, CPz, CP2, CP4 и Pz) в) 8-30 Гц; г) 5 с, анализируемый сигнал 0,5-4,5 с</p>	<p>а) выбор специфичной для испытуемого частотной полосы на основе спектрограмм; б) ковариационные матрицы, переход к TS Римана; в) LDA; г) Neighborhood Component Feature Selection</p>	<p>а) 96,66 б) 0,933 в) hold-out</p>
[57]	<p>а) 2, П. рука, Л. нога; б) 118 (BCI Comp. III/4a) ; в) 7-30 Гц; г) 3,5 с, анализируемый сигнал 0,5-2,5 с</p>	<p>а) децимация до 100 Гц, CSP, переход к TS; б) проекции ковариационных матриц в TS; в) SVM; г) Sparse Regression Model, уменьшение размерности с помощью LDA</p>	<p>а) 89,69 б) – в) 10-fold CV, усреднение 10 реализаций</p>
	<p>а) 2, Л./П. руки; б) 59 (BCI Comp. IV/1) ; в) 7-30 Гц; г) 4 с, анализируемый сигнал 0,5-2,5 с</p>		<p>а) 81,9 б) – в) 10-fold CV, усреднение 10 реализаций</p>
[53]	<p>а) 2, Л./П. руки; б) 64; в) 8-30 Гц; г) 4 с, анализируемый сигнал 1-3 с</p>	<p>а) переход к TSSM (Tangent Space of Sub-Manifold) ; б) проекции ковариационных матриц в TSSM; в) SVM; г) –</p>	<p>а) 90; б) – в) 30-fold CV</p>

Примечание 1: CSP – Common Spatial Pattern, (FG)MRDM – (Filter Geodesic) Minimum Riemannian Distance to Mean, TS – Tangent Space, LDA – Linear Discriminant Analysis, GDA – Generalized Discriminant Analysis, kNN – k-nearest Neighbors (метод ближайших соседей).

Примечание 2: в методе hold-out используется тестовая выборка, в методе N-fold CV данные разбиваются на N частей, и поочередно каждая часть служит в качестве тестовой выборки, а все остальные части – в качестве тренировочной выборки.

Таблица 6. Применение римановой геометрии в режиме онлайн

	Данные	Классификация	Эксперимент
Статья	а) число классов, воображаемые движения; б) количество ЭЭГ отведений при анализе; в) анализируемый диапазон частот; г) длительность пробы	а) предобработка; б) используемые признаки; в) метод классификации; г) метод выбора признаков	а) обратная связь; б) точность (%); в) задержка; г) метод оценки
[3]	а) 2, покой, педалирование; б) 8 (FC1, FC2, C3, Cz, C4, Cp1, Cp2 и Pz) ; в) 0, 1-30 Гц; г) 5 с, эпоха анализа 1 с	а) - б) ковариационные матрицы, переход к TS Римана; в) LDA; г) Fast Neighborhood Component Analysis, Pair-Wise Feature Proximity	а) – б) 69,3; в) 328 мс; г) hold-out

Примечание 1: TS – Tangent Space, LDA – Linear Discriminant Analysis.

Примечание 2: в методе hold-out используется тестовая выборка.

10. Применение методов глубинного обучения (Deep Learning) для классификации ЭЭГ сигналов. Согласно данным, представленным в таблице 7, использование методов глубокого обучения позволило получить лучшие результаты для классификации 4х классов воображаемых движений, равные 93,7% [50], при этом использовался вектор амплитуд сигналов и свёрточная нейросеть, которая агрегирует характеристики ЭЭГ, вычисленные во временных окнах разного размера (масштаба). Для двухклассовой классификации

лучший результат составил 95% при использовании вектора амплитуд сигналов и глубокой стековой сети (Deep Stacking Network) [62]. В первом случае – количество электродов равнялось 128, во втором – 6. В среднем по рассмотренным исследованиям (табл. 7) точность классификации 2х классов составила $81,7 \pm 4,7\%$ – в большинстве работ (9 из 13) используются данные от трех отведений, расположенных в сенсомоторной коре. Таким образом, методы глубокого обучения могут позволить использовать малое количество электродов при распознавании сигнала в режиме реального времени. В [37] сверточная нейронная сеть была использована для управления роботом-манипулятором в режиме онлайн с задержкой 1,4 с (табл. 8).

Таблица 7. Применение методов глубинного обучения в режиме офлайн

	Данные	Классификация	Результат
Статья	а) число классов, воображаемые движения; б) количество ЭЭГ отведений при анализе; в) анализируемый диапазон частот; г) длительность пробы	а) предобработка; б) используемые признаки; в) метод классификации; г) метод выбора признаков	а) точность; б) каппа; в) метод оценки
[30]	а) 2, Л./П. руки; б) 22; в) 8-36 Гц; г) 4 с, эпоха анализа 3 с, шаг 0,3 с	а) FBCSP, TS; б) PSD, вектора проекций TS; в) CNN; г) Particle Swarm Optimization	а) 80,44 б) – в) hold-out
	а) 2, Л./П. руки; б) 3 (C3, Cz, C4); в) 8-36 Гц; г) 4 с, эпоха анализа 3 с, шаг 0,3 с		а) 82,39 б) – в) hold-out
[58]	а) 2, Л./П. руки; б) 3 (C3, Cz, C4); в) 4-38 Гц; г) 4 с, анализируемый сигнал 0,5-2,5 с	а) – б) спектрограммы; в) CapsNet; г) –	а) 78,44; б) –
[50]	а) 4, Л./П. руки, язык, покой; б) 128; в) не указан; г) 4 с, анализируемый сигнал (-0,5)-4 с	а) аугментация путём добавления шума; б) вектор амплитуд сигнала; в) Mixed-Scale CNN; г) –	а) 93,7; б) – в) hold-out

Продолжение таблицы 7

[59]	а) 2, Л./П. руки; б) 3 (С3, Сz, С4); в) 6-30 Гц; г) 4 с, анализируемый сигнал 2 с	а) – б) спектрограммы; в) CNN + VAE; г) –	а) 78,4; б) 0,568; в) 10-fold CV, усреднение 10 реализаций
	а) 2, Л./П. руки; б) 5 (С3, С1, Сz, С2, С4); в) 6-30 Гц; г) 6 с, анализируемый сигнал 2 с		а) 80,2; б) 0,603; в) 10-fold CV, усреднение 10 реализаций
[19]	а) 2, Л./П. руки; б) 3 (С3, Сz, С4) – VCI Comp. IV/2b; в) 0,5-100 Гц; г) 4 с	а) аугментация данных с помощью GAN; б) спектрограммы; в) CNN + MLP; г) –	а) 74,8; б) – в) hold-out
	а) 2, Л./П. руки; б) 32; в) 0,5-100 Гц; г) не указана		а) 76,4; б) – в) hold-out
[60]	а) 3, Л./П. руки, покой; б) 64; в) 8-35 Гц; г) 5 с, анализируемый сигнал 0,5-4,5 с, эпоха анализа 1 с, шаг 0,2 с	а) – б) PSD (Lomb-Scargie Periodogram); в) Deep Belief Network; г) –	а) 70; б) – в) hold-out
[61]	а) 2, Л./П. руки; б) 3 (С3, Сz, С4); в) 8-35 Гц; г) 5 с, анализируемый сигнал 0,5-4,5 с, эпоха анализа 1 с, шаг 0,2 с	а) Exponential Weighted Moving Average; б) вектор амплитуд сигнала; в) Deep Belief Network; г) –	а) 84,3; б) – в) hold-out, усреднение 10 реализаций
[37]	а) 2, Л./П. руки; б) 3 (С3, Сz, С4); в) 2-60 Гц; г) 4 с, анализируемый сигнал (-3)-4 с, эпоха анализа 4 с, шаг 125 мс	а) – б) спектрограммы (STFT); в) CNN; г) –	а) 84,24; б) – в) 5-fold CV

Продолжение таблицы 7

[62]	а) 2, Л./П. руки; б) 6 (F3, F4, Fc5, Fc6, T7, T8); в) 8-30 Гц; г) 2 с	а) – б) вектор амплитуд сигнала; в) Deep Stacking Network; г) –	а) 95; б) – в) hold-out
	а) 2, Л./П. руки; б) 3 (C3, Cz, C4) – VCI Comp. IV/2b; в) 0,5-100 Гц; г) 4 с	а) – б) вектор амплитуд сигнала; в) Deep Stacking Network; г) –	а) 83,55 б) – в) hold-out
[52]	а) 2, Л./П. руки; б) 3 (C3, Cz, C4) – VCI Comp. IV/2b; в) 8-30 Гц; г) 4 с, анализируемый сигнал 1-3 с	а) FBCSP; б) вектор амплитуд сигнала; в) LSTM-RNN; г) –	а) 81,52; б) – в) не указан
	а) 2, Л./П. руки; б) 3 (C3, Cz, C4) – VCI Comp. IV/2b; в) 8-30 Гц; г) 4 с, анализируемый сигнал 1-3 с	а) FBCSP; б) вектор амплитуд сигнала; в) GRU-RNN; г) –	а) 82,75; б) – в) не указан

Примечание 1: ConvNet, CNN – Convolutional Neural Network, CapsNet – Capsule Network, VAE – Variational Autoencoder, GAN – Generative Adversarial Network, MLP – Multi-Layer Perceptron, LSTM – Long Short-Term Memory, CSP – Common Spatial Pattern, TS – Tangent Space, PSD – Power Spectral Density.

Примечание 2: в методе hold-out используется тестовая выборка, в методе N-fold CV данные разбиваются на N частей, и каждая часть поочередно служит в качестве тестовой выборки, а все остальные части – в качестве тренировочной выборки.

Таблица 8. Применение методов глубинного обучения в режиме онлайн

	Данные	Классификация	Эксперимент
Статья	а) число классов, воображаемые движения б) количество ЭЭГ отведений при анализе в) анализируемый диапазон частот г) длительность пробы	а) предобработка б) используемые признаки в) метод классификации г) метод выбора признаков	а) обратная связь б) точность (%) в) задержка г) метод оценки

Продолжение таблицы 8

[37]	а) 3, Л./П. руки, покой б) 3 (С3, Cz, C4) в) 2-60 Гц г) не указана	а) – б) спектрограммы (STFT) в) CNN г) –	а) робот-манипулятор б) не указана в) 1,4 с г) не указан
------	---	---	---

Примечание: CNN – Convolutional Neural Network, STFT – Short-Time Fourier Transform.

11. Сравнение разрешающей способности рассмотренных методов классификации. Преобразование CSP преобразование дает оптимальные среди линейных методов фильтры, позволяющие различить два класса состояний [24]. При использовании CSP в нескольких частотных полосах можно подстроить классификатор под индивидуальные особенности человека, выбрав наилучший диапазон для анализа. Эта идея была использована в работе [20], показавшей наилучший результат в рамках набора данных VCI Competition IV/2a при индивидуальном выборе частотных полос ЭЭГ данных для CSP – значение каппа составило 0,57, что в случае 4 классов соответствует точности 67,75%. Преобразование FBSCP часто используется в качестве основного подхода для сравнения (baseline-модели) в задачах классификации воображаемых движений.

Поскольку классификаторы на основе римановой геометрии, а также глубинные нейронные сети являются нелинейными, эти модели могут превзойти результаты, получаемые с помощью оптимального линейного CSP. С использованием набора данных VCI Competition IV/2a в работе [17], в которой описаны сверточные сети DeepNet и ShallowNet, был показан выигрыш в точности относительно FBSCP в 2,9% и 5,7%, соответственно. Модель, описанная в работе [48] и использующая комбинацию преобразования CSP, сверточных сетей и LSTM-ячеек, показывает наибольшую среди рассмотренных работ точность для набора данных VCI Competition IV – 83% (табл. 2) для 4-х классов.

В работах, где для классификации используется концепция римановой геометрии, наблюдается менее значительное превосходство по точности относительно CSP: прирост в 2,77% в [33], прирост в 1,7% в [53], а также проигрыш в 0,25% в [27]. Тем не менее концепция римановой геометрии позволяет более эффективно осуществлять перенос обучения [14], описанный подробнее в следующем разделе.

Как показал анализ данных, применение методов глубокого обучения предполагает в основном использование сырого сигнала. В

то же время, применение концепции римановой геометрии или преобразования CSP позволяет получить преобразованный сигнал ЭЭГ, пригодный для использования с классическими методами машинного обучения.

Вышеописанные результаты были приведены для офлайн-режима тестирования. В онлайн-режиме помимо точности классификации важно также время, необходимое для предсказания класса пробы. В [37] было показано, что при классификации воображаемых сжатий левой и правой руки с использованием сверточной нейронной сети задержка составляла 1,4 с, в то время как в работе [4], использующей преобразование CSP, задержка была равна 430 мс. Таким образом, в практических приложениях в случае, когда выигрыш в точности от использования нелинейных методов невелик, на первый план может выходить быстрдействие системы, и большинство работ среди рассмотренных использовали именно преобразование CSP в режиме онлайн. Однако использование римановой геометрии в режиме онлайн является перспективной стратегией, позволяющей достичь малых временных задержек (328 мс [3]).

12. Частные случаи. При классификации сигналов ЭЭГ возникает несколько специфических ограничений, которые необходимо преодолеть: сравнительно небольшое количество данных для обучения, а также необходимость адаптивности и/или робастности классификатора по отношению к изменению функционального состояния человека. Известно, что функциональное состояние постепенно изменяется по мере утомления пациента в пределах одной сессии регистрации ЭЭГ [63] или может резко измениться, например, под действием эмоций [64, 65]. В разные дни вариативность состояний в целом выше [15]. В ситуации направленной заданной деятельности ЭЭГ-паттерн более «стабилен», чем в условиях спонтанной активности [66]. В частности, реализация движений и их кинестетическое воображение (конечностями) в большинстве случаев характеризуется «устойчивым» паттерном десинхронизации ЭЭГ в контралатеральном полушарии на частотах сенсомоторного и бета ритмов ЭЭГ [67].

В ряде работ описаны методы классификации ЭЭГ-паттернов при использовании для обучения небольшого количества проб [68, 69]. Например, в работе [69] для классификации 3-х видов воображаемых движений одной рукой (сжатие кисти, щипковый захват (пальцами) и движение в локте с длительностью пробы 4 с) предложен адаптивный CSP. Адаптация CSP проводилась с использованием набора данных VCI competition IV dataset IIa – запись ЭЭГ от 22 электродов при выполнении 4-х воображаемых движений: левой и правой рукой, движение ногами и

языком (длительность пробы 3 с) – по 72 пробы каждого класса для каждого из 9 испытуемых. На этом наборе данных использование адаптивного CSP в отличие от фиксированного CSP приводило к значимому увеличению точности классификации при малом количестве проб в каждом классе. Точность фиксированного CSP линейно росла при использовании от 10 до 70 проб для обучения (результатирующая каппа – около 0,5), в то время как адаптивный CSP даже при использовании 10 проб каждого типа позволял достичь показателей каппа 0,45 и после 30 проб – переставал увеличиваться, достигая 0,52 для классификации четырех типов движений. При использовании адаптированного CSP при классификации новых данных (трех воображаемых движений одной рукой) и обучении на малом количестве проб (36 проб каждого класса) среднее значение каппы составило 0,474 по сравнению с 0,113 – для фиксированного DL CSP.

Для достижения адаптивности могут быть использованы различные подходы к выбору окон анализа и частотных фильтров. Так в работе [29] предлагается новый алгоритм – групповой пространственный фильтр с ограничением времени (*temporally constrained sparse group spatial pattern (TSGSP)*) – для индивидуального выбора пространственных фильтров и временного окна анализа. В данной работе адаптированный CSP применялся для классификации воображаемых движений из трех наборов данных: (i) VCI Competition III dataset IIIa – запись ЭЭГ от 60 электродов при выполнении 4х воображаемых движений: левой и правой рукой, движение ногами и языком (длительность пробы 4 с), по 180, 120 и 120 проб для трех испытуемых; (ii) VCI Competition IV datasets IIa – запись ЭЭГ от 22 электродов при выполнении 4-х воображаемых движений: левой и правой рукой, движение ногами и языком (длительность пробы 3с), по 72 пробы каждого класса для каждого из 9 испытуемых; (iii) VCI Competition IV dataset IIb – запись ЭЭГ от 3х электродов (C3, Cz, C4) при выполнении 2 воображаемых движений: левой и правой рукой (длительность пробы 4.5 с), по 160 проб каждого класса для каждого из 9 испытуемых. Наборы данных (i), (ii) были разделены для двухклассовой классификации по принципу: движение левой/правой рукой и движение ногами/языком; (iii) – оставался без изменений. Точность классификации с использованием предложенного алгоритма выбора признаков (TSGSP) и SVM в качестве классификатора достигала 88.5%, 83.3% и 84.3% соответственно.

Альтернативным подходом является перенос обучения (*transfer learning*), при котором часть проб в процессе тестирования используется для переобучения классификатора [14]. В [14] на примере набора данных

BCI Competition 2008, содержащих данные двух сессий из 4-х воображаемых движений – правой/левой рукой, ногами и языком (длительность пробы 4 с), рассмотрена возможность использования в качестве обучающей выборки данные одной сессии, а для тестирующей – данные другой сессии. Также допускается использование данных разных испытуемых. При использовании классификатора на основе римановой геометрии наблюдаются существенные различия распределений пространственных матриц ковариации, полученных в разных сессиях и у разных испытуемых, что осложняет перенос обучения. Предложено использовать аффинное преобразование для сближения ковариационных матриц, соответствующих разным испытуемым или разным сессиям, в римановом пространстве. Применение данного метода привело к значимому улучшению результатов по сравнению с обычным подходом (в отсутствие преобразования), в особенности при использовании данных для обучения и тестирования от разных испытуемых – без преобразования точность классификации 4-х движений составляла от 30 до 46%, после преобразования – от 57 до 69%.

Целая серия исследований проводится для уменьшения времени записи тренировочных сессий, используемых для обучения классификатора. В условиях реального времени редукция количества данных происходит и за счет артефактов.

В [60] рассматривается возможность классификации частично «поврежденного» сигнала (проб с моторным воображением) с помощью комбинации трех разных методов выделения признаков: оценки спектральной плотности сигнала – быстрого преобразования Фурье, Вельша (Welch), метода Ломба – Скаргла (Lomb-Scargle periodogram) и методов глубинного обучения (глубокая сеть доверия на основе машины Больцмана с ограниченной связностью) и SVM.

Так в работе использовались пробы с воображаемыми движениями: движение левой/правой рукой, и движение ногами. Период моторного воображения составлял 5 с из которых 4 с (0.5-4.5 с) использовались для анализа (всего 300 проб с моторным воображением). Для анализа каждая четырехсекундная проба была разделена на 16 участков с перекрыванием 80% и длиной 1 с. Из данных участков ЭЭГ (случайным образом удаляли от 10 до 80% отсчетов). Было показано, что использование метода Ломба – Скаргла и глубокой сети доверия (Deep Belief Network) на основе машины Больцмана с ограниченной связностью позволяет с большей точностью классифицировать пробы с моторным воображением при потере до 80% сигнала по сравнению с быстрым преобразованием

Фурье и Вельша. Снижение точности наблюдалось для всех методов: от $74.77 \pm 0.43\%$ при классификации полных данных до $64.17 \pm 0.63\%$ (для метода Ломба – Скаргла) и около 51% (для методов Вельша и быстрого преобразования Фурье). Рассмотренные примеры работ направлены на улучшение потребительских свойств ИМК: ускорение обучения и повышение точности классификаторов, а также облегчение использования при разработке методов, устойчивых к «выбросам» и артефактам ЭЭГ-данных.

13. Заключение. Задача классификации сигналов ЭЭГ принципиально меняется при переходе от фиксированного набора данных к реальным экспериментам, поскольку классификатору необходимо подстраиваться под изменения функционального состояния человека, а также укладываться во временные ограничения режима работы в реальном времени. Как показал анализ данных, в условиях онлайн режима чаще используются более простые методы классификации, такие как LDA или SVM, а при тестировании методов на фиксированных наборах данных ЭЭГ (Data Sets) – широкий спектр методов машинного обучения. Для извлечения признаков в онлайн-режиме часто применяются CSP и CSD-преобразование (или фильтр Лапласа, преобразование Хьюрта).

Основным отличием онлайн тестирования является наличие обратной связи – испытуемый получает информацию о том, успешно ли было распознано классификатором сделанное испытуемым очередное воображаемое движение. В качестве обратной связи практикуется управление роботами Nao [16] и механической рукой [37], экзоскелетом [2] или курсором [54]. Управление может осуществляться дискретно (действие либо совершается, либо нет) или «непрерывно» (например, скорость курсора линейно зависит от мощности мю-ритма).

В целом рассмотренные работы демонстрируют преимущество использования римановой геометрии для классификации ЭЭГ-паттернов воображаемых движений в офлайн режиме, где точность двухклассовой классификации в среднем составляет $90,2 \pm 6,6\%$ против $77,5 \pm 5,8\%$ при использовании CSP и $81,7 \pm 4,7\%$ при использовании сетей глубоко обучения. Количество работ по онлайн-классификации с использованием римановой геометрии и сетей глубокого обучения еще очень мало.

Так как в онлайн-режиме исключительно важна минимизация временных задержек подачи обратной связи, то при незначительном выигрыше в точности на первый план выходит быстрдействие системы, что при прочих равных условиях получено в большинстве

работ с использованием преобразования CSP в режиме онлайн и работ в контуре концепции римановой геометрии.

Литература

1. Официальный сайт базы данных медицинских и биологических публикаций Pubmed, созданной Национальным центром биотехнологической информации США. URL: <https://pubmed.ncbi.nlm.nih.gov> (дата обращения: 15.01.2021).
2. Tang Z. et al. A Brain-Machine Interface Based on ERD/ERS for an Upper-Limb Exoskeleton Control // *Sensors*. 2016. vol. 16. no. 12. pp. 2050.
3. Romero-Laiseca M.A. et al. A Low-Cost Lower-Limb Brain-Machine Interface Triggered by Pedaling Motor Imagery for Post-Stroke Patients Rehabilitation // *IEEE Trans. Neural Syst. Rehabil. Eng.* 2020. vol. 28. pp. 988–996.
4. Belwafi K. et al. An embedded implementation based on adaptive filter bank for brain-computer interface systems // *Journal of Neuroscience Methods*. 2018. vol. 305. pp. 1–16.
5. Cervera M.A. et al. Brain-computer interfaces for post-stroke motor rehabilitation: a meta-analysis // *Ann. Clin. Transl. Neurol.* 2018. vol. 5. no. 5. pp. 651–663.
6. Bockbrader M.A. et al. Brain Computer Interfaces in Rehabilitation Medicine // *PM&R*. 2018. vol. 10. no. 9. pp. S233–S243.
7. Бирюкова Е.В. и др. Восстановление двигательной функции руки с помощью экзоскелета кисти, управляемого интерфейсом мозг-компьютер. случай пациента с обширным поражением мозговых структур // *Физиология человека*. 2016. Т. 42. № 1. С. 19–30.
8. Asensio-Cubero J., Gan J.Q., Palaniappan R. Multiresolution analysis over graphs for a motor imagery based online BCI game // *Comput. Biol. Med.* 2016. vol. 68. pp. 21–26.
9. Stankevich L.A. et al. EEG pattern decoding of rhythmic individual finger imaginary movements of one hand // *Human Physiology*. 2016. vol. 42. no. 1. pp. 32.
10. Lotte F. et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update // *J Neural Eng.* 2018. vol. 15. no. 3. pp. 031005.
11. Zhao X., Zhao J., Liu C., Cai W. Deep Neural Network with Joint Distribution Matching for Cross-Subject Motor Imagery Brain-Computer Interfaces // *Biomed. Res. Int.* 2020. vol. 2020. no. 7285057.
12. Sonkin K.M. et al. Development of electroencephalographic pattern classifiers for real and imaginary thumb and index finger movements of one hand // *Artif Intell Med.* 2015. vol. 63. no. 2. pp. 107–117.
13. Xu L. et al. Cross-Dataset Variability Problem in EEG Decoding With Deep Learning // *Front. Hum. Neurosci.* 2020. vol. 14. pp. 103.
14. Zanini P. et al. Transfer Learning: A Riemannian Geometry Framework With Applications to Brain-Computer Interfaces // *IEEE Trans. Biomed. Eng.* 2018. vol. 65. no. 5. pp. 1107–1116.
15. Rodrigues P.L.C., Jutten C., Congedo M. Riemannian Procrustes Analysis: Transfer Learning for Brain-Computer Interfaces // *IEEE Trans. Biomed. Eng.* 2019. vol. 66. no. 8. pp. 2390–2401.
16. Ai Q. et al. Feature extraction of four-class motor imagery EEG signals based on functional brain network // *J. Neural Eng.* 2019. vol. 16. no. 2. pp. 026032.
17. Schirrmester R.T. et al. Deep learning with convolutional neural networks for EEG decoding and visualization // *Human Brain Mapping*. 2017. vol. 38. no. 11. pp. 5391–5420.
18. Hartmann K. G., Schirrmester R. T., Ball T. EEG-GAN: Generative adversarial networks for electroencephalographic (EEG) brain signals // *arXiv.org*. 2018. URL: <http://arxiv.org/abs/1806.01875> (дата обращения: 07.09.2020).
19. Yang B. et al. A Framework on Optimization Strategy for EEG Motor Imagery Recognition. Proceedings of the 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2019. pp. 774–777.

20. *Ang K.K. et al.* Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b // *Front. Neurosci.* 2012. vol. 6. no. 39.
21. *Gaur P., Pachori R.B., Wang H., Prasad G.* A multi-class EEG-based BCI classification using multivariate empirical mode decomposition based filtering and Riemannian geometry // *Expert Systems with Applications.* 2018. vol. 95. pp. 201–211.
22. *McFarland D.J., McCane L.M., David S.V., Wolpaw J. R.* Spatial filter selection for EEG-based communication // *Electroencephalography and Clinical Neurophysiology.* 1997. vol. 103. no. 3. pp. 386–394.
23. *Fukunaga K.* Introduction to Statistical Pattern Recognition (2nd ed.) // New York: Academic Press. 1990. 592 p.
24. *Ramoser H., Müller-Gerking J., Pfurtscheller G.* Optimal spatial filtering of single trial EEG during imagined hand movement // *IEEE Trans. Rehab. Eng.* 2000. vol. 8. no. 4. pp. 441–446.
25. *Müller-Gerking J., Pfurtscheller G., Flyvbjerg H.* Designing optimal spatial filters for single-trial EEG classification in a movement task // *Electroenc. Clin. Neurophys.* 1999. vol. 110. no. 5. pp. 787–798.
26. *Meng J. et al.* Noninvasive Electroencephalogram Based Control of a Robotic Arm for Reach and Grasp Tasks // *Sci. Rep.* 2016. vol 6. no. 38565.
27. *Barachant A., Bonnet S., Congedo M., Jutten C.* Multiclass Brain–Computer Interface Classification by Riemannian Geometry // *IEEE Trans. Biomed. Eng.* 2012. vol. 59. no. 4. pp. 920–928.
28. *Lei B. et al.* Walking Imagery Evaluation in Brain Computer Interfaces via a Multi-View Multi-Level Deep Polynomial Network // *IEEE Trans. Neural Syst. Rehabil. Eng.* 2019. vol. 27. no. 3. pp. 497–506.
29. *Zhang Z. et al.* Modeling EEG-based Motor Imagery with Session to Session Online Adaptation. Proceedings of the 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2018. pp. 1988–1991.
30. *Majidov I., Whangbo T.* Efficient Classification of Motor Imagery Electroencephalography Signals Using Deep Learning Methods // *Sensors.* 2019. vol. 19. no. 7. pp. 1736.
31. *Delisle-Rodriguez D. et al.* System based on subject-specific bands to recognize pedaling motor imagery: towards a BCI for lower-limb rehabilitation // *J. Neural Eng.* 2019. vol. 16. no. 056005.
32. *Lotte F. et al.* A review of classification algorithms for EEG-based brain-computer interfaces // *J. Neural Eng.* 2007. vol. 4. no. 2. pp. R1.
33. *Guan S., Zhao K., Yang S.* Motor Imagery EEG Classification Based on Decision Tree Framework and Riemannian Geometry // *Computational Intelligence and Neuroscience.* 2019. vol. 2019. no. 5627156.
34. *Frolov A.A. et al.* Post-stroke Rehabilitation Training with a Motor-Imagery-Based Brain-Computer Interface (BCI)-Controlled Hand Exoskeleton: A Randomized Controlled Multicenter Trial // *Front. Neurosci.* 2017. vol. 11. pp. 400.
35. *Lisi G., Rivela D., Takai A., Morimoto J.* Markov Switching Model for Quick Detection of Event Related Desynchronization in EEG // *Front. Neurosci.* 2018. vol. 12. p. 24. doi: 10.3389/fnins.2018.00024
36. *Lawhern V.J. et al.* EEGNet: A Compact Convolutional Network for EEG-based Brain-Computer Interfaces // *J. Neural Eng.* 2018. vol. 15. no. 056013.
37. *Tayeb Z. et al.* Validating Deep Neural Networks for Online Decoding of Motor Imagery Movements from EEG Signals // *Sensors.* 2019. vol. 19. no. 1. p. 210.
38. *Schalk G. et al.* BCI2000: A General-Purpose Brain-Computer Interface (BCI) System // *IEEE TBME.* 2004. vol. 51. no. 6. pp. 1034–1043.
39. *Gramfort A. et al.* MEG and EEG data analysis with MNE-Python // *Front. Neurosci.* 2013. vol. 7. pp. 267.

40. *Tangermann M. et al.* Review of the BCI Competition IV // *Front. Neurosci.* 2012. vol. 6. pp. 5.
41. *Manton J.H.* A globally convergent numerical algorithm for computing the centre of mass on compact Lie groups // *Proceedings of the ICARCV Conference.* 2004. pp. 2211–2216.
42. *Barachant A., Bonnet S., Congedo M., Jutten C.* Classification of covariance matrices using a Riemannian-based kernel for BCI applications // *Neurocomputing.* 2013. vol. 112. pp. 172–178.
43. *Congedo M., Barachant A.* A special form of SPD covariance matrix for interpretation and visualization of data manipulated with Riemannian geometry. *Proceedings of the Bayesian Inference and Maximum Entropy Methods in Science and Engineering.* 2014. pp. 495–503.
44. *Haykin S.* *Neural Networks: A Comprehensive Foundation* (2 ed.). // Prentice Hall, 1998. 842 p.
45. *Hinton G. E., Salakhutdinov R.R.* Reducing the Dimensionality of Data with Neural Networks // *Science.* 2006. vol. 313. no. 5786. pp. 504–507.
46. *LeCun Y. et al.* Backpropagation Applied to Handwritten Zip Code Recognition // *Neural Computation.* 1989. vol. 1. no. 4. pp. 541–551.
47. *Hochreiter S., Schmidhuber J.* Long short-term memory // *Neural Computation.* 1997. vol. 9. no. 8. pp. 1735–1780.
48. *Brunner C., Leeb R., Mueller-Putz G., Schlögl A., Pfurtscheller G.* BCI Competition 2008 – Graz data set A. URL: http://bbci.de/competition/iv/desc_2a.pdf (дата обращения: 07.09.2020).
49. *Zhang R., Zong Q., Dou L., Zhao X.* A novel hybrid deep learning scheme for four-class motor imagery classification // *J. Neural Eng.* 2019. vol. 16. no. 6. pp. 066004.
50. *Li Y. et al.* A Channel-Projection Mixed-Scale Convolutional Neural Network for Motor Imagery EEG Decoding // *IEEE Trans. Neural Syst. Rehabil. Eng.* 2019. vol. 27. no. 6. pp. 1170–1180.
51. *Sakhavi S., Guan C., Yan S.* Learning Temporal Information for Brain-Computer Interface Using Convolutional Neural Networks // *IEEE Trans. Neural Netw. Learning Syst.* 2018. vol. 29. no. 11. pp. 5619–5629.
52. *Luo T., Zhou C., Chao F.* Exploring spatial-frequency-sequential relationships for motor imagery classification with recurrent neural network // *BMC Bioinformatics.* 2018. vol. 19. no. 344.
53. *Xie X. et al.* Motor Imagery Classification Based on Bilinear Sub-Manifold Learning of Symmetric Positive-Definite Matrices // *IEEE Trans. Neural Syst. Rehabil. Eng.* 2016. vol. 25. no. 6. pp. 504–516.
54. *Meng J. et al.* A Study of the Effects of Electrode Number and Decoding Algorithm on Online EEG-Based BCI Behavioral Performance // *Front. Neurosci.* 2018. vol. 12. pp. 227.
55. *Singh A., Lal S., Guesgen H.* Reduce Calibration Time in Motor Imagery Using Spatially Regularized Symmetric Positive-Definite Matrices Based Classification // *Sensors.* 2019. vol. 19. no. 2. pp. 379.
56. *Gurue D. et al.* Subject-specific EEG channel selection using non-negative matrix factorization for lower-limb motor imagery recognition // *J. Neural Eng.* 2020. vol. 17. no. 2. p. 026029.
57. *Kumar S., Mamun K., Sharma A.* CSP-TSM: Optimizing the performance of Riemannian tangent space mapping using common spatial pattern for MI-BCI // *Computers in Biology and Medicine.* 2017. vol. 91. pp. 231–242.
58. *Ha K.-W., Jeong J.-W.* Motor Imagery EEG Classification Using Capsule Networks // *Sensors.* 2019. vol. 19. no. 13. pp. 2854.
59. *Dai M. et al.* EEG Classification of Motor Imagery Using a Novel Deep Learning Framework // *Sensors.* 2019. vol. 19. no. 3. pp. 551.
60. *Chu Y. et al.* A Decoding Scheme for Incomplete Motor Imagery EEG With Deep Belief Network // *Front. Neurosci.* 2018. vol. 12. pp. 680.

61. *Wu H et al.* A Parallel Multiscale Filter Bank Convolutional Neural Networks for Motor Imagery EEG Classification // *Front. Neurosci.* 2019. vol. 13. pp. 1275.
62. *Tang X.-L., Ma W.-C., Kong D.-S., Li W.* Semisupervised Deep Stacking Network with Adaptive Learning Rate Strategy for Motor Imagery EEG Recognition // *Neural Computation.* 2019. vol. 31. no. 5. pp. 919–942. doi:10.1162/neco_a_01183
63. *Foong R. et al.* Assessment of the Efficacy of EEG-Based MI-BCI With Visual Feedback and EEG Correlates of Mental Fatigue for Upper-Limb Stroke Rehabilitation // *IEEE Trans. Biomed. Eng.* 2020. vol. 67. no. 3. pp. 786–795.
64. *Shemyakina N.V., Dan'ko S.G.* Changes in the power and coherence of the β_2 EEG band in subjects performing creative tasks using emotionally significant and emotionally neutral words // *Hum. Physiol.* 2007. vol. 33. pp. 20–26.
65. *Шемякина Н.В., Данько С.Г.* Влияние эмоциональной окраски воспринимаемого сигнала на электроэнцефалографические корреляты творческой деятельности // *Физиология человека.* 2004. Т. 30. № 2. С. 22–29.
66. *Schmidt H., Avitabile D., Montbrío E., Roxin A.* Network mechanisms underlying the role of oscillations in cognitive tasks // *PLoS Comput. Biol.* 2018. vol. 14. no. 9. pp. e1006430. doi: 10.1371/journal.pcbi.1006430. PMID: 30188889; PMCID: PMC6143269.
67. *Neuper C., Scherer R., Reiner M., Pfurtscheller G.* Imagery of motor actions: differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG // *Cogn. Brain. Res.* 2005. vol. 25. no. 3. pp. 668–677.
68. *She Q. et al.* A hierarchical semi-supervised extreme learning machine method for EEG recognition // *Med. Biol. Eng. Comput.* 2019. vol. 57. pp. 147–157.
69. *Costa A.P., Møller J.S., Iversen H.K., Puthusserypady S.* An adaptive CSP filter to investigate user independence in a 3-class MI-BCI paradigm // *Comput. Biol. Med.* 2018. vol. 103. pp. 24–33.

Капралов Николай Владимирович – младший научный сотрудник, Междисциплинарная лаборатория нейробиологии, Институт эволюционной физиологии и биохимии им. И.М. Сеченова РАН (ИЭФБ РАН). Область научных интересов: искусственный интеллект, когнитивные системы, антропоморфная робототехника, интерфейсы «мозг-компьютер». Число научных публикаций – 5. nikolay.kapralov@gmail.com; Тореза, 44, 194233, Санкт-Петербург, Россия; р.т.: +79119636947; факс: +7(812)552-3012.

Нагорнова Жанна Владимировна – канд. биол. наук, старший научный сотрудник, Лаборатория сравнительных эколого-физиологических исследований, Институт эволюционной физиологии и биохимии им. И.М. Сеченова РАН (ИЭФБ РАН). Область научных интересов: методы анализа биоэлектрических сигналов, возрастная физиология, нейрофизиология творческой деятельности и ассоциативного мышления, интерфейсы «мозг-компьютер», воображаемые движения. Число научных публикаций – 25. nagornova_zh@mail.ru; Тореза, 44, 194233, Санкт-Петербург, Россия; р.т.: +7 (960) 266-7304; факс: +7 (812) 552-3012.

Шемякина Наталья Вячеславовна – канд. биол. наук, ведущий научный сотрудник, Лаборатория сравнительных эколого-физиологических исследований, Институт эволюционной физиологии и биохимии им. И.М. Сеченова РАН (ИЭФБ РАН). Область научных интересов: методы анализа биоэлектрических сигналов, возрастная физиология, нейрофизиология творческой деятельности и ассоциативного мышления, интерфейсы «мозг-компьютер», воображаемые движения. Число научных публикаций – 31. shemyakina_n@mail.ru; Тореза, 44, 194233, Санкт-Петербург, Россия; р.т.: +7 (911) 224-8293; факс: +7 (812) 552-3012.

Поддержка исследований. Работа выполнена в рамках гос. задания ИЭФБ РАН.

N. KAPRALOV, Zh. NAGORNOVA, N. SHEMYAKINA
**CLASSIFICATION METHODS FOR EEG PATTERNS OF
IMAGINARY MOVEMENTS**

Kapralov N., Nagornova Zh., Shemyakina N. Classification Methods for EEG Patterns of Imaginary Movements.

Abstract. The review focuses on the most promising methods for classifying EEG signals for non-invasive BCIs and theoretical approaches for the successful classification of EEG patterns. The paper provides an overview of articles using Riemannian geometry, deep learning methods and various options for preprocessing and "clustering" EEG signals, for example, common-spatial pattern (CSP). Among other approaches, pre-processing of EEG signals using CSP is often used, both offline and online. The combination of CSP, linear discriminant analysis, support vector machine and neural network (BPNN) made it possible to achieve 91% accuracy for binary classification with exoskeleton control as a feedback. There is very little work on the use of Riemannian geometry online and the best accuracy achieved so far for a binary classification problem is 69.3% in the work. At the same time, in offline testing, the average percentage of correct classification in the considered articles for approaches with CSP – $77.5 \pm 5.8\%$, deep learning networks – $81.7 \pm 4.7\%$, Riemannian geometry – $90.2 \pm 6.6\%$. Due to nonlinear transformations, Riemannian geometry-based approaches and complex deep neural networks provide higher accuracy and better extract of useful information from raw EEG recordings rather than linear CSP transformation. However, in real-time setup, not only accuracy is important, but also a minimum time delay. Therefore, approaches using the CSP transformation and Riemannian geometry with a time delay of less than 500 ms may be in the future advantage.

Keywords: EEG Patterns, Motor Imagination, Common Spatial Pattern, Riemannian Geometry, Deep Learning Methods, ANN

References

1. Oficial'nyj sajt bazy dannyh medicinskih i biologicheskikh publikacij Pubmed, sozdannoj Nacional'nym centrom biotekhnologicheskoy informacii SSHA. [Official website of Pubmed database of references and abstracts on life sciences and biomedical topics, maintained by the National Center for Biotechnology Information, USA]. Available at: <https://pubmed.ncbi.nlm.nih.gov> (accessed 15.01.2021) (In Russ.).
2. Tang Z. et al. A Brain-Machine Interface Based on ERD/ERS for an Upper-Limb Exoskeleton Control. *Sensors*. 2016. vol. 16. no. 12. pp. 2050.
3. Romero-Laiseca M.A. et al. A Low-Cost Lower-Limb Brain-Machine Interface Triggered by Pedaling Motor Imagery for Post-Stroke Patients Rehabilitation. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2020. vol. 28. pp. 988–996.
4. Belwafi K. et al. An embedded implementation based on adaptive filter bank for brain-computer interface systems. *Journal of Neuroscience Methods*. 2018. vol. 305. pp. 1–16.
5. Cervera M.A. et al. Brain-computer interfaces for post-stroke motor rehabilitation: a meta-analysis. *Ann. Clin. Transl. Neurol.* 2018. vol. 5. no. 5. pp. 651–663.
6. Bockbrader M.A. et al. Brain Computer Interfaces in Rehabilitation Medicine. *PM&R*. 2018. vol. 10. no. 9. pp. S233–S243.
7. Birjukova E.V. et al. [Restoration of the hand motor functions using the exoskeleton hand controlled by the brain-computer interface. The case of severely damaged brain structures]. *Fiziologija cheloveka – Human Physiology*. 2016. Issue 42. vol. 1. pp. 19–30.
8. Asensio-Cubero J., Gan J.Q., Palaniappan R. Multiresolution analysis over graphs for a motor imagery based online BCI game. *Comput. Biol. Med.* 2016. vol. 68. pp. 21–26.

9. Stankevich L.A. et al. EEG pattern decoding of rhythmic individual finger imaginary movements of one hand. *Human Physiology*. 2016. vol. 42. no. 1. pp. 32.
10. Lotte F. et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *J Neural Eng*. 2018. vol. 15. no. 3. pp. 031005.
11. Zhao X., Zhao J., Liu C., Cai W. Deep Neural Network with Joint Distribution Matching for Cross-Subject Motor Imagery Brain-Computer Interfaces. *Biomed. Res. Int*. 2020. vol. 2020. no. 7285057.
12. Sonkin K.M. et al. Development of electroencephalographic pattern classifiers for real and imaginary thumb and index finger movements of one hand. *Artif Intell Med*. 2015. vol. 63. no. 2. p. 107–117.
13. Xu L. et al. Cross-Dataset Variability Problem in EEG Decoding With Deep Learning. *Front. Hum. Neurosci*. 2020. vol. 14. pp. 103.
14. Zanini P. et al. Transfer Learning: A Riemannian Geometry Framework With Applications to Brain-Computer Interfaces. *IEEE Trans. Biomed. Eng*. 2018. vol. 65. no. 5. pp. 1107–1116.
15. Rodrigues P.L.C., Jutten C., Congedo M. Riemannian Procrustes Analysis: Transfer Learning for Brain-Computer Interfaces. *IEEE. Trans. Biomed. Eng*. 2019. vol. 66. no. 8. pp. 2390–2401.
16. Ai Q. et al. Feature extraction of four-class motor imagery EEG signals based on functional brain network. *J. Neural Eng*. 2019. vol. 16. no. 2. pp. 026032.
17. Schirrneister R.T. et al. Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*. 2017. vol. 38. no. 11. pp. 5391–5420.
18. Hartmann K. G., Schirrneister R. T., Ball T. EEG-GAN: Generative adversarial networks for electroencephalographic (EEG) brain signals. arXiv.org. 2018. Available at: <http://arxiv.org/abs/1806.01875> (accessed: 07.09.2020).
19. Yang B. et al. A Framework on Optimization Strategy for EEG Motor Imagery Recognition. Proceedings of the 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2019. pp. 774–777.
20. Ang K.K. et al. Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b. *Front. Neurosci*. 2012. vol. 6. no. 39.
21. Gaur P., Pachori R.B., Wang H., Prasad G. A multi-class EEG-based BCI classification using multivariate empirical mode decomposition based filtering and Riemannian geometry. *Expert Systems with Applications*. 2018. vol. 95. pp. 201–211.
22. McFarland D.J., McCane L.M., David S.V., Wolpaw J. R. Spatial filter selection for EEG-based communication. *Electroencephalography and Clinical Neurophysiology*. 1997. vol. 103. no. 3. pp. 386–394.
23. Fukunaga K. Introduction to Statistical Pattern Recognition (2nd ed.). New York: Academic Press. 1990. 592 p.
24. Ramoser H., Müller-Gerking J., Pfurtscheller G. Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Trans. Rehab. Eng*. 2000. vol. 8. no. 4. pp. 441–446.
25. Müller-Gerking J., Pfurtscheller G., Flyvbjerg H. Designing optimal spatial filters for single-trial EEG classification in a movement task. *Electroenc. Clin. Neurophys*. 1999. vol. 110. no. 5. pp. 787–798.
26. Meng J. et al. Noninvasive Electroencephalogram Based Control of a Robotic Arm for Reach and Grasp Tasks. *Sci. Rep*. 2016. vol 6. no. 38565.
27. Barachant A., Bonnet S., Congedo M., Jutten C. Multiclass Brain–Computer Interface Classification by Riemannian Geometry. *IEEE Trans. Biomed. Eng*. 2012. vol. 59. no. 4. pp. 920–928.
28. Lei B. et al. Walking Imagery Evaluation in Brain Computer Interfaces via a Multi-View Multi-Level Deep Polynomial Network. *IEEE Trans. Neural Syst. Rehabil. Eng*. 2019. vol. 27. no. 3. pp. 497–506.

29. Zhang Z. et al. Modeling EEG-based Motor Imagery with Session to Session Online Adaptation. Proceedings of the 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2018. pp. 1988–1991.
30. Majidov I., Whangbo T. Efficient Classification of Motor Imagery Electroencephalography Signals Using Deep Learning Methods. *Sensors*. 2019. vol. 19. no. 7. pp. 1736.
31. Delisle-Rodriguez D. et al. System based on subject-specific bands to recognize pedaling motor imagery: towards a BCI for lower-limb rehabilitation. *J. Neural Eng.* 2019. vol. 16. no. 056005.
32. Lotte F. et al. A review of classification algorithms for EEG-based brain-computer interfaces. *J. Neural Eng.* 2007. vol. 4. no. 2. pp. R1.
33. Guan S., Zhao K., Yang S. Motor Imagery EEG Classification Based on Decision Tree Framework and Riemannian Geometry. *Computational Intelligence and Neuroscience*. 2019. vol. 2019. no. 5627156.
34. Frolov A.A. et al. Post-stroke Rehabilitation Training with a Motor-Imagery-Based Brain-Computer Interface (BCI)-Controlled Hand Exoskeleton: A Randomized Controlled Multicenter Trial. *Front. Neurosci.* 2017. vol. 11. pp. 400.
35. Lisi G., Rivela D., Takai A., Morimoto J. Markov Switching Model for Quick Detection of Event Related Desynchronization in EEG. *Front. Neurosci.* 2018. vol. 12. p. 24. doi: 10.3389/fnins.2018.00024
36. Lawhern V.J. et al. EEGNet: A Compact Convolutional Network for EEG-based Brain-Computer Interfaces. *J. Neural Eng.* 2018. vol. 15. no. 056013.
37. Tayeb Z. et al. Validating Deep Neural Networks for Online Decoding of Motor Imagery Movements from EEG Signals. *Sensors*. 2019. vol. 19. no. 1. p. 210.
38. Schalk G. et al. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE TBME*. 2004. vol. 51. no. 6. pp. 1034–1043.
39. Gramfort A. et al. MEG and EEG data analysis with MNE-Python. *Front. Neurosci.* 2013. vol. 7. pp. 267.
40. Tangermann M. et al. Review of the BCI Competition IV. *Front. Neurosci.* 2012. vol. 6. pp. 5.
41. Manton J.H. A globally convergent numerical algorithm for computing the centre of mass on compact Lie groups. Proceedings of the ICARCV Conference. 2004. pp. 2211–2216.
42. Barachant A., Bonnet S., Congedo M., Jutten C. Classification of covariance matrices using a Riemannian-based kernel for BCI applications. *Neurocomputing*. 2013. vol. 112. pp. 172–178.
43. Congedo M., Barachant A. A special form of SPD covariance matrix for interpretation and visualization of data manipulated with Riemannian geometry. Proceedings of the Bayesian Inference and Maximum Entropy Methods in Science and Engineering. 2014. pp. 495–503.
44. Haykin S. *Neural Networks: A Comprehensive Foundation* (2 ed.). Prentice Hall, 1998. 842 p.
45. Hinton G. E., Salakhutdinov R.R. Reducing the Dimensionality of Data with Neural Networks. *Science*. 2006. vol. 313. no. 5786. pp. 504–507.
46. LeCun Y. et al. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*. 1989. vol. 1. no. 4. pp. 541–551.
47. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computation*. 1997. vol. 9. no. 8. pp. 1735–1780.
48. Brunner C., Leeb R., Mueller-Putz G., Schlögl A., Pfurtscheller G. BCI Competition 2008 – Graz data set A. Available at: http://bbci.de/competition/iv/desc_2a.pdf (accessed: 07.09.2020).
49. Zhang R., Zong Q., Dou L., Zhao X. A novel hybrid deep learning scheme for four-class motor imagery classification. *J. Neural Eng.* 2019. vol. 16. no. 6. pp. 066004.

50. Li Y. et al. A Channel-Projection Mixed-Scale Convolutional Neural Network for Motor Imagery EEG Decoding. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2019. vol. 27. no. 6. pp. 1170–1180.
51. Sakhavi S., Guan C., Yan S. Learning Temporal Information for Brain-Computer Interface Using Convolutional Neural Networks. *IEEE Trans. Neural Netw. Learning Syst.* 2018. vol. 29. no. 11. pp. 5619–5629.
52. Luo T., Zhou C., Chao F. Exploring spatial-frequency-sequential relationships for motor imagery classification with recurrent neural network. *BMC Bioinformatics.* 2018. vol. 19. no. 344.
53. Xie X. et al. Motor Imagery Classification Based on Bilinear Sub-Manifold Learning of Symmetric Positive-Definite Matrices. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2016. vol. 25. no. 6. pp. 504–516.
54. Meng J. et al. A Study of the Effects of Electrode Number and Decoding Algorithm on Online EEG-Based BCI Behavioral Performance. *Front. Neurosci.* 2018. vol. 12. pp. 227.
55. Singh A., Lal S., Guesgen H. Reduce Calibration Time in Motor Imagery Using Spatially Regularized Symmetric Positives-Definite Matrices Based Classification. *Sensors.* 2019. vol. 19. no. 2. pp. 379.
56. Gurve D. et al. Subject-specific EEG channel selection using non-negative matrix factorization for lower-limb motor imagery recognition. *J. Neural Eng.* 2020. vol. 17. no. 2. p. 026029.
57. Kumar S., Mamun K., Sharma A. CSP-TSM: Optimizing the performance of Riemannian tangent space mapping using common spatial pattern for MI-BCI. *Computers in Biology and Medicine.* 2017. vol. 91. pp. 231–242.
58. Ha K.-W., Jeong J.-W. Motor Imagery EEG Classification Using Capsule Networks. *Sensors.* 2019. vol. 19. no. 13. pp. 2854.
59. Dai M. et al. EEG Classification of Motor Imagery Using a Novel Deep Learning Framework. *Sensors.* 2019. vol. 19. no. 3. pp. 551.
60. Chu Y. et al. A Decoding Scheme for Incomplete Motor Imagery EEG With Deep Belief Network. *Front. Neurosci.* 2018. vol. 12. pp. 680.
61. Wu H et al. A Parallel Multiscale Filter Bank Convolutional Neural Networks for Motor Imagery EEG Classification. *Front. Neurosci.* 2019. vol. 13. pp. 1275.
62. Tang X.-L., Ma W.-C., Kong D.-S., Li W. Semisupervised Deep Stacking Network with Adaptive Learning Rate Strategy for Motor Imagery EEG Recognition. *Neural Computation.* 2019. vol. 31. no. 5. pp. 919–942. doi:10.1162/neco_a_01183
63. Foong R. et al. Assessment of the Efficacy of EEG-Based MI-BCI With Visual Feedback and EEG Correlates of Mental Fatigue for Upper-Limb Stroke Rehabilitation. *IEEE Trans. Biomed. Eng.* 2020. vol. 67. no. 3. pp. 786–795.
64. Shemyakina N.V., Dan'ko S.G. Changes in the power and coherence of the β_2 EEG band in subjects performing creative tasks using emotionally significant and emotionally neutral words. *Hum. Physiol.* 2007. vol. 33. pp. 20–26.
65. Shemyakina N.V., Dan'ko S.G. [Influence of the emotional perception of a signal on the electroencephalographic correlates of the creative activity]. *Fiziologija cheloveka – Human Physiology.* 2004. Issue 30. vol. 2. pp. 22–29. (In Russ.)
66. Schmidt H., Avitabile D., Montbrió E., Roxin A. Network mechanisms underlying the role of oscillations in cognitive tasks. *PLoS Comput. Biol.* 2018. vol. 14. no. 9. pp. e1006430.
67. Neuper C., Scherer R., Reiner M., Pfurtscheller G. Imagery of motor actions: differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG. *Cogn. Brain. Res.* 2005. vol. 25. no. 3. pp. 668–677.
68. She Q. et al. A hierarchical semi-supervised extreme learning machine method for EEG recognition. *Med. Biol. Eng. Comput.* 2019. vol. 57. pp. 147–157.

69. Costa A.P., Møller J.S., Iversen H.K., Puthusserypady S. An adaptive CSP filter to investigate user independence in a 3-class MI-BCI paradigm. *Comput. Biol. Med.* 2018. vol. 103. pp. 24–33

Kapralov Nikolai – Junior Researcher, Interdisciplinary Laboratory of Neuroscience, Sechenov Institute of Evolutionary Physiology and Biochemistry RAS (IEPHB RAS). Research interests: artificial intelligence, cognitive systems, anthropomorphic robotics, brain-computer interfaces. The number of publications – 5. nikolay.kapralov@gmail.com; 44, Toreza, 194233, St. Petersburg, Russia; office phone: +79119636947; fax: +7(812)552-3012.

Nagornova Zhanna – Ph.D., Senior Researcher, Laboratory of Comparative Ecological and Physiological Studies, Sechenov Institute of Evolutionary Physiology and Biochemistry RAS (IEPHB RAS). Research interests: imagination, age physiology, analysis of EEG signals, brain-computer interfaces. The number of publications – 25. nagornova_zh@mail.ru; 44, Toreza, 194233, St. Petersburg, Russia; office phone: +7 (960) 266-7304; fax: +7 (812) 552-3012.

Shemyakina Natalia – Ph.D., Leading Researcher, Laboratory of Comparative Ecological and Physiological Studies, Sechenov Institute of Evolutionary Physiology and Biochemistry RAS (IEPHB RAS). Research interests: methods for analyzing bioelectric signals, age physiology, neurophysiology of creative activity and associative thinking, brain-computer interfaces, imaginary movements. The number of publications – 31. shemyakina_n@mail.ru; 44, Toreza, 194233, St. Petersburg, Russia; office phone: +7 (911) 224-8293; fax: +7 (812) 552-3012.

Acknowledgements. This research is supported by state assignment of IEPHB RAS.