

УДК 004.5

Выделение характерных признаков сигнала электроэнцефалограммы с помощью анализа энтропии

Сотников П. И.^{1,*}

^{*}sotnikoffp@gmail.com

¹МГТУ им. Н.Э. Баумана, Москва, Россия

В работе представлены краткие сведения об интерфейсах мозг-компьютер (ИМК), основанных на преобразовании мысленного представления движений в команды внешнему техническому устройству. Показана возможность применения в таких интерфейсах анализа энтропии для выделения характерных признаков сигнала электроэнцефалограммы (ЭЭГ). Описан алгоритм формирования вектора характерных признаков на основе расчета энтропии Шеннона. На тестовых данных, предоставленных для соревнования BCI Competition IV, выполнена оценка эффективности предлагаемого метода по сравнению с рядом других методов, нашедших широкое применение в приложениях ИМК.

Ключевые слова: интерфейс мозг-компьютер (ИМК), выделение признаков электроэнцефалограммы (ЭЭГ), анализ энтропии, энтропия Шеннона, метод опорных векторов

Введение

Одним из типов неинвазивных интерфейсов мозг-компьютер (ИМК) (англ. *Brain-Computer Interface, BCI*), демонстрирующих высокую производительность, является ИМК на основе анализа сенсомоторных ритмов (англ. *sensorimotor rhythms - SMR*), регистрируемых с помощью электроэнцефалограммы (ЭЭГ). В таких интерфейсах пользователь осуществляет управление внешним устройством, например, рукой робота или курсором на экране, с помощью мысленного представления того или иного движения.

При выполнении или мысленном представлении движений различных частей тела происходит активация соответствующих моторных участков коры головного мозга и в отведениях ЭЭГ, расположенных над этими участками, наблюдается *десинхронизация* мю- и бета-ритмов [1,2]. В то же время в состоянии покоя сенсомоторные ритмы имеют высокую амплитуду (то есть наблюдается *синхронизация* ритмов).

Главной задачей ИМК в рассматриваемом случае является корректное распознавание состояний синхронизации и десинхронизации ритмов. Для решения этой задачи осуществляется переход от многоканального сигнала ЭЭГ к некоторому вектору признаков, характеризующих сигнал.

В данной статье рассматривается метод выделения характерных признаков, основанный на анализе энтропии сигнала. Производится оценка эффективности предлагаемого метода по сравнению с рядом других методов, нашедших широкое применение в приложениях ИМК. В качестве показателя эффективности используется значение вероятности правильного распознавания типов воображаемых движений.

1. Формирование вектора характерных признаков с помощью анализа энтропии сигнала

Пусть исходный ЭЭГ сигнал X содержит данные, полученные по M отведениям (каналам). При этом в каждом отведении $m \in \{1, 2, \dots, M\}$ сигнал представлен в виде совокупности дискретных отсчетов, взятых в моменты времени с номерами $n = 0, 1, \dots, N - 1$, где N – общее число отсчетов.

Переход от многомерного временного ряда X , описывающего сигнал, к некоторому вектору признаков, характеризующему этот временной ряд, в операторной форме можно записать как

$$\Phi(X) = V, \quad V \in R^L,$$

где $\Phi(X)$ – оператор, выполняющий отображение исходного ЭЭГ сигнала X в пространство характерных признаков; V – вектор характерных признаков; L – размерность данного вектора.

В задачах распознавания типов воображаемых движений к наиболее распространенным методам выделения характерных признаков относятся следующие:

- статистический анализ сигнала [3];
- спектральный анализ сигнала с помощью дискретного преобразования Фурье [1,4];
- анализ сигнала в частотно-временной области с помощью вейвлет-преобразования [5,6];
- пространственная фильтрация многоканального ЭЭГ сигнала [7,8];
- авторегрессионная модель сигнала [9].

В дополнение к перечисленным выше методам в данной статье рассматривается возможность формирования вектора характерных признаков V с помощью анализа энтропии сигнала.

Применительно к анализу ЭЭГ, информационная энтропия сигнала служит мерой неопределенности (непредсказуемости) значений амплитуды ЭЭГ сигнала [10].

При выполнении движений или их мысленном представлении, повышается уровень активности больших групп нейронов, отвечающих за управление тем или иным органом. Это вызывает выраженную *десинхронизацию* в работе нейронов и, как следствие, сопровождается изменением формы ЭЭГ сигнала в отведениях, расположенных над соответствующими участками коры головного мозга. Сигнал в данных отведениях приобретает шумоподобный вид. В то же время, в состоянии покоя степень функциональной активности мозга снижается, наблюдается *синхронизация* в работе

нейронов, что влечет за собой появление на ЭЭГ низкочастотных колебаний достаточно высокой амплитуды.

Для описания информационных свойств аналогового сигнала $x(t)$ используется понятие энтропии непрерывной случайной величины.

Разобьем весь диапазон $[x_{min}; x_{max}]$ наблюдаемых значений величины $x(t)$ на K интервалов, шириной Δx каждый. Воспользовавшись формулой Шеннона, выражение для расчета энтропии непрерывной случайной величины можно представить в виде

$$H(x) = - \sum_{i=1}^K p(x_i) \log_2 p(x_i), \quad (1)$$

где $p(x_i)$ – вероятность того, что значение сигнала $x(t)$ лежит в пределах i -того интервала квантования; K – общее число интервалов разбиения.

Пусть исходный сигнал задан в виде последовательности отсчетов $x(n)$, взятых в моменты времени с номерами $n = 0, 1, \dots, N - 1$. Тогда в выражении (1) от значений вероятностей $p(x_i)$ можно перейти к их оценкам – частотам появления величины $x(n)$ в каждом интервале квантования:

$$p_i = \frac{n_i}{N}, \quad i = 1, 2, \dots, K. \quad (2)$$

Здесь n_i – число значений величины $x(n)$, приходящихся на i -тый интервал.

С учетом (2), выражение (1) для расчета энтропии можно переписать в виде

$$H(x) = - \sum_{i=1}^K p_i \log_2 p_i.$$

На практике удобно использовать нормированное значение энтропии, которое показывает долю полученной энтропии от максимально возможной при заданном числе интервалов разбиения K . В аналитическом виде формула для расчета нормированной энтропии выглядит как

$$H'(x) = \frac{H(x)}{H_{\max}}.$$

При фиксированном значении числа интервалов разбиения, максимальной энтропией обладает сигнал, имеющий равномерное распределение значений по всему диапазону $[x_{min}; x_{max}]$. В случае равномерного распределения справедливо равенство $p_i = \frac{1}{K}$. Значение максимальной энтропии при этом определяется как

$$H_{\max} = - \sum_{i=1}^K \frac{1}{K} \log_2 \frac{1}{K} = \log_2 K.$$

Для устранения влияния возможных артефактов в записи ЭЭГ на конечный результат, перед вычислением энтропии производится фильтрация сигнала, целью которой является усиление или ослабление определенных частотных составляющих сигнала. Для фильтрации сигнала, представленного в виде последовательности дискретных отсчетов, применяют дискретные фильтры, которые в общем случае можно разделить на фильтры с конечной импульсной характеристикой (англ. *Finite Impulse*

Response, FIR) и с бесконечной импульсной характеристикой (англ. *Infinite Impulse Response, IIR*).

В работе для подавления помех и выделения частотных составляющих ЭЭГ сигнала, соответствующих диапазонам сенсомоторных ритмов, применялся *FIR*-фильтр с оконным сглаживанием.

В качестве оконной функции выбрана функция Кайзера, определяемая как

$$b(p) = \tilde{b}(p) \frac{I_0\left(\beta \sqrt{1 - \left(\frac{2p-P}{P}\right)^2}\right)}{I_0(\beta)}, p = \{0, 1, \dots, P\},$$

где $\tilde{b}(p)$, $b(p)$ – коэффициенты фильтра до и после применения оконного сглаживания; P – порядок фильтра; I_0 – модифицированная функция Бесселя первого рода нулевого порядка; β – коэффициент, определяющий долю энергии, сосредоточенной в главном лепестке спектра оконной функции.

В качестве полосы пропускания выбран диапазон частот от 7 до 30 Гц, соответствующий мю- и бета-ритмам сигнала ЭЭГ [2]. Порядок фильтра определен как половина частоты дискретизации, с которой осуществлялась оцифровка сигнала. Для эффективного снижения уровня боковых лепестков спектра значение коэффициента β для оконной функции установлено равным 10.

В итоговый вектор характерных признаков V включаются значения нормированной энтропии $H(x)$, рассчитанные для каждого из каналов ЭЭГ сигнала. Размерность вектора V , таким образом, равна $L = M$.

2. Построение классификатора. Метод опорных векторов

В ряде публикаций было показано, что в приложениях ИМК линейные методы классификации, такие как Байесов классификатор, линейный дискриминантный анализ, метод опорных векторов, обладают эффективностью, не уступающей нелинейным методам, например, на основе искусственных нейронных сетей [11]. В связи с этим в данной работе был выбран классификатор на основе метода опорных векторов.

Пусть имеется обучающая выборка $\{\mathbf{v}_q, y_q\}_{q=1}^Q$ объема Q , где $\mathbf{v}_q \in R^L$ – признаковое описание многомерного ЭЭГ сигнала, $y_q \in \{-1, +1\}$ – метка класса, принимающая одно из двух возможных значений. В методе опорных векторов (англ. *Support Vector Machine*) решение о принадлежности объекта $\mathbf{v}$ к классу y принимается по знаку линейного решающего правила [12]:

$$f(\mathbf{v}) = \sum_{i=1}^L w_i v(i) + b = \mathbf{w}^T \mathbf{v} + b, \quad y(\mathbf{v}) = \begin{cases} +1, & \text{если } f(\mathbf{v}) \geq 0, \\ -1, & \text{если } f(\mathbf{v}) < 0. \end{cases}$$

Здесь $w_i \in R$ – некоторые веса; $b \in R$ – параметр сдвига. С геометрической точки зрения линейный классификатор соответствует некоторой разделяющей гиперплоскости $f(\mathbf{v}) = 0$ в признаковом пространстве R^L , при этом объект относится к первому классу,

если он лежит с положительной стороны от гиперплоскости, и ко второму классу – в противном случае.

Определим зазор d между классом и гиперплоскостью $f(\mathbf{v}) = 0$ как минимальное расстояние между этой гиперплоскостью и объектом класса. Тогда задача построения классификатора сводится к поиску такой разделяющей гиперплоскости, зазор между которой и объектами первого и второго класса будет максимальным. Через параметры $\mathbf{w}$, b зазор можно выразить как $d = 1/\|\mathbf{w}\|$. В итоге задача максимизации зазора записывается следующим образом:

$$\begin{cases} \frac{2}{\|\mathbf{w}\|} \rightarrow \max_{\mathbf{w} \in R^L, b \in R}, \\ \mathbf{w}^T \mathbf{v}_q + b \geq 1, & \text{если } y_q = 1, \\ \mathbf{w}^T \mathbf{v}_q + b \leq -1, & \text{если } y_q = -1; \end{cases} \leftrightarrow \begin{cases} \frac{1}{2} \|\mathbf{w}\|^2 \rightarrow \min_{\mathbf{w} \in R^L, b \in R}, \\ y_q (\mathbf{w}^T \mathbf{v}_q + b) \geq 1, & q = 1, 2, \dots, Q. \end{cases}$$

Стоит отметить, что на практике классы часто бывают линейно неразделимы. Поэтому для метода опорных векторов был предложен ряд модификаций, допускающих ошибки на обучающей выборке. Одной из таких модификаций является метод «*nu-SVM*», в котором задача поиска разделяющей гиперплоскости сводится к следующей задаче условной оптимизации [13]:

$$\begin{cases} \tau(\mathbf{w}, \xi, \rho) = \frac{1}{2} \|\mathbf{w}\|^2 - \nu \rho + \frac{1}{2} \sum_{q=1}^Q \xi_q \rightarrow \min_{\mathbf{w} \in R^L, \xi \in R^Q, \rho, b \in R}, \\ y_q (\mathbf{w}^T \mathbf{v}_q + b) \geq \rho - \xi_q, & q = 1, 2, \dots, Q, \\ \rho \geq 0, \quad \xi_q \geq 0. \end{cases}$$

Здесь $\xi = (\xi_1, \xi_2, \dots, \xi_Q)$ – ослабляющие коэффициенты. Варьируемый параметр $\nu \in [0, 1]$ задает верхнюю границу доли ошибок обучения и нижнюю границу числа опорных векторов.

Метод опорных векторов может быть расширен на число классов, большее двух. Для этого задача разбивается на несколько бинарных подзадач, в которых сравнение производится по схеме «каждый с каждым» или «один со всеми».

3. Описание тестовых данных

Для оценки эффективности рассматриваемого алгоритма выделения характерных признаков использовались тестовые данные *Dataset Ia*, предоставленные Технологическим университетом Граца для проведения соревнования «*BCI Competition IV*» [14]. В состав тестовых данных входят записи электроэнцефалограммы, снятые для девяти испытуемых (мужского и женского пола). Каждый из испытуемых участвовал в двух сессиях, проводимых в разные дни.

В течение сессии испытуемому предлагалось мысленно представлять движения следующих типов: левой рукой (класс 1); правой рукой (класс 2); ногами (класс 3); языком (класс 4). Испытуемый располагался в мягком кресле напротив экрана компьютера. В

начале каждой пробы ($t = 0$, с) для привлечения внимания в центре экрана появлялся крест, сопровождаемый звуком сигналом. Спустя 2 секунды на экране появлялась стрелка, указывающая влево, вправо, вниз или вверх, в зависимости от типа воображаемого движения. После предъявления стрелки испытуемый должен был представлять движение требуемого класса. При этом обратной связи не использовалось. В момент времени $t = 6$, с экран становился черным, что говорило об окончании пробы.

Запись ЭЭГ осуществлялась с помощью 22 электродов, расположенных как это показано на рисунке 1а. В качестве референтного использовался электрод, закрепленный на левом мастоиде; в качестве заземления - электрод на правом мастоиде. Запись ЭЭГ проводилась с частотой дискретизации 250 Гц; чувствительность усилителя была установлена равной 100 мкВ. Дополнительно выполнялась регистрация электроокулограммы (ЭОГ) с помощью трех электродов, расположенных как показано на рисунке 1б.




Рис. 1. Схемы расположения электродов: а) при регистрации ЭЭГ; б) для записи ЭОГ

Во время каждой сессии было записано по 288 проб (по 72 пробы каждого класса). В работе данные, полученные в ходе первой сессии, были использованы в качестве обучающей выборки, данные, полученные в ходе второй сессии, - в качестве тестовой выборки.

4. Результаты экспериментальных исследований

Сравнение эффективности метода выделения характерных признаков, основанного на анализе энтропии сигнала ЭЭГ, проводилось со следующими методами.

- а) Статистический анализ сигнала. В качестве признаков использовались значения дисперсии сигнала в каждом из каналов записи ЭЭГ;

- б) Дискретное преобразование Фурье. Каждому каналу ЭЭГ сопоставлялось пять признаков, которые представляли собой значения суммарной спектральной плотности мощности в частотных диапазонах: 1-4 Гц (дельта-ритм); 4-8 Гц (тета-ритм); 8-14 Гц (альфа-ритм); 14-30 Гц (бета-ритм); 30-50 Гц (гамма-ритм) [2].
- в) Непрерывное вейвлет-преобразование. Вектор характерных признаков в данном случае включал в себя средние значения энергии сигнала для каждого из ЭЭГ каналов в указанных выше частотных диапазонах;
- г) Векторная модель авторегрессии. В качестве характерных признаков использовались коэффициенты авторегрессии. Порядок модели был выбран равным единице;
- д) Общий пространственный фильтр. Вектор характерных признаков формировался из значений дисперсии в первых трех каналах сигнала, полученного после фильтрации. Реализация вычислительных алгоритмов была выполнена в среде разработки «LabVIEW», при этом применялись следующие библиотечные функции:
- функции библиотеки *FIR Filter* для расчета коэффициентов частотного фильтра;
 - инструмент *Power Spectrum VI* из библиотеки *Spectral Analysis VIs* для оценки спектральной плотности мощности сигнала;
 - инструмент *WA Analytic Wavelet Transform VI* из библиотеки функций *Continuous Wavelet VIs* для расчета коэффициентов вейвлет-разложения;
 - инструмент *TSA AR Modeling VI* из библиотеки *Modeling and Prediction VIs* для расчета параметров модели авторегрессии;
 - инструмент *IMAQ Train SVM VI* из библиотеки *Classifier Engines* для построения классификатора на основе метода опорных векторов.

Для каждой из проб вектор характерных признаков рассчитывался для отрезка записи ЭЭГ, соответствующего интервалу времени от момента предъявления стимула на экране компьютера до окончания пробы. При вычислении характерных признаков каналы, соответствующие электроокулограмме (каналы 23,24,25), не использовались.

При расчете нормированной энтропии диапазон значений ЭЭГ сигнала был выбран равным от -100 до 100 мкВ, что соответствует физическим ограничениям электроэнцефалографа. Число интервалов разбиения выбрано равным 100.

На векторах характерных признаков, полученных для обучающей выборки, производилось обучение *nu-SVM* классификатора. На векторах, полученных для тестовой выборки, оценивалась точность классификатора. В качестве показателя точности использовалось значение вероятности правильного распознавания типов воображаемых движений.

Поскольку точность *nu-SVM* классификатора зависит от параметра ν , значение ν варьировалось в диапазоне от 0,1 до 0,95 с шагом 0,05. В качестве итоговой точности классификатора, достижимой для данного метода выделения характерных признаков, принималась максимальная из полученных.

Для оценки влияния предобработки на конечную точность классификации было выполнено три эксперимента.

Вектора характерных признаков рассчитывались для исходного сигнала ЭЭГ, не подвергнувшегося предварительной обработки (за исключением частотной фильтрации);

Перед вычислением характерных признаков был сделан перерасчет значений сигнала ЭЭГ относительно общего усредненного референта;

Перед вычислением характерных признаков с помощью анализа главных компонентов было произведено удаление из сигнала ЭЭГ артефактов, связанных с движением глаз.

В таблице 1 приведены рассчитанные значения вероятности правильного распознавания типов воображаемых движений для первого эксперимента. Для четырех классов вероятность «случайной» классификации составляет 25%.

Таблица 1. Оценки точности классификации для методов выделения характерных признаков
(Эксперимент I, ЭЭГ без предобработки).

Испытуемый	Дисперсия сигнала	Спектральная плотность мощности	Вейвлет-преобразование	Модель авторегрессии	CSP-фильтр	Нормированная энтропия сигнала
A01	0,62	0,58	0,61	0,56	0,66	0,64
A02	0,40	0,38	0,45	0,39	0,63	0,36
A03	0,68	0,64	0,69	0,49	0,64	0,67
A04	0,45	0,39	0,44	0,40	0,34	0,44
A05	0,37	0,35	0,29	0,35	0,34	0,33
A06	0,41	0,37	0,43	0,35	0,40	0,39
A07	0,49	0,49	0,58	0,45	0,46	0,50
A08	0,56	0,58	0,55	0,48	0,53	0,56
A09	0,62	0,57	0,63	0,50	0,68	0,64
Сред	0,51	0,48	0,52	0,44	0,52	0,50

В строках A01 – A09 таблицы жирным выделены наибольшие значения точности классификации для каждого из испытуемых. В последней строке таблицы приведены средние значения точности классификации для каждого из методов.

В таблице 2 приведены полученные оценки точности классификации для второго эксперимента, в котором перед расчетом характерных признаков был выполнен переход к общему усредненному монтажу [2].

Таблица 2. Оценки точности классификации для методов выделения характерных признаков
(Эксперимент II, Общий усредненный монтаж).


Испытуемый	Дисперсия сигнала	Спектральная плотность мощности	Вейвлет-преобразование	Модель авторегрессии	CSP-фильтр	Нормированная энтропия сигнала
A01	0,70	0,69	0,69	0,59	0,66	0,70
A02	0,55	0,51	0,54	0,46	0,60	0,55
A03	0,62	0,69	0,66	0,48	0,63	0,67
A04	0,50	0,47	0,50	0,36	0,37	0,45
A05	0,39	0,40	0,25	0,39	0,30	0,40
A06	0,43	0,40	0,44	0,38	0,37	0,43
A07	0,47	0,55	0,55	0,49	0,40	0,54
A08	0,58	0,63	0,65	0,53	0,55	0,65
A09	0,65	0,64	0,65	0,53	0,66	0,72
Сред	0,54	0,55	0,55	0,47	0,50	0,57

Полученные оценки точности классификации для третьего эксперимента, в котором перед формированием векторов характерных признаков производилось удаление из сигнала ЭЭГ артефактов ЭОГ, приведены в таблице 3.


Таблица 3. Оценки точности классификации для методов выделения характерных признаков
(Эксперимент III, ЭЭГ без компоненты артефактов).

Испытуемый	Дисперсия сигнала	Спектральная плотность мощности	Вейвлет-преобразование	Модель авторегрессии	CSP-фильтр	Нормированная энтропия сигнала
A01	0,60	0,55	0,56	0,53	0,66	0,59
A02	0,50	0,49	0,53	0,42	0,60	0,50
A03	0,66	0,59	0,59	0,48	0,63	0,66
A04	0,38	0,41	0,41	0,38	0,36	0,40
A05	0,33	0,31	0,32	0,37	0,30	0,31
A06	0,38	0,37	0,41	0,40	0,38	0,40
A07	0,44	0,48	0,50	0,47	0,39	0,48
A08	0,52	0,53	0,55	0,44	0,61	0,51
A09	0,61	0,58	0,64	0,50	0,66	0,65
Сред	0,49	0,48	0,50	0,44	0,51	0,50


В графической форме результаты экспериментов представлены на рисунке 2, где разные кривые соответствуют разным методам выделения характерных признаков.



а) Эксперимент I, ЭЭГ без предобработки



б) Эксперимент II, Общий усредненный монтаж



в) Эксперимент III, ЭЭГ без компоненты артефакта

— Дисперсия
— Вейвлет-преобразование
— CSP-фильтр
— Спектральная плотность мощности
— Модель авторегрессии
— Нормированная энтропия

Рис. 2. Графики зависимости точности классификации от особенностей испытуемых

5. Анализ полученных результатов

Как видно из таблиц 1-3, наибольшая средняя точность классификации (0,57) достигается при перерасчете значений сигнала ЭЭГ относительно общего усредненного референта и формировании вектора характерных признаков с помощью анализа энтропии сигнала.

После удаления из сигнала ЭЭГ артефактов, связанных с движениями глаз, наблюдается некоторое снижение точности классификации (таблица 3). Данный факт может быть вызван как тем, что при проведении двух сессий у испытуемых в ряде случаев возникали одинаковые специфические движения глаз, связанные с предъявляемым стимулом, так и ложноположительными срабатываниями классификатора.

Оценка статистической значимости полученных результатов проводилась с помощью двухфакторного дисперсионного анализа (англ. *Analysis of variance*, ANOVA). В качестве одного источника вариации выступали различия оценок, обусловленные индивидуальными особенностями испытуемых. В качестве второго источника – различия, связанные с применяемыми методами выделения признаков. Уровень значимости, при котором отвергается нулевая гипотеза, был принят равным $\alpha = 0,05$.

Поскольку наибольшая средняя точность классификации была получена во втором эксперименте, предположение о более высокой эффективности метода выделения характерных признаков на основе анализа энтропии сигнала исследовалось на данных, представленных в таблице 2.

После выполнения анализа установлено, что метод на основе расчета энтропии обладает большей эффективностью по сравнению с методами на основе построения модели авторегрессии (г) и общего пространственного фильтра (д) (соответствующие p -значения $p_{\Gamma} = 0,001, p_{\text{д}} = 0,007$). При этом различия в точности классификации между методами на основе анализа энтропии и методами расчета дисперсии сигнала (а), спектральной плотности мощности (б), вейвлет-преобразования (в) не являются статистически значимыми (соответствующие p -значения $p_{\text{а}} = 0,115, p_{\text{б}} = 0,193, p_{\text{в}} = 0,342$).

Предположение о влиянии предобработки ЭЭГ сигнала на конечную точность классификации является статистически значимым для методов выделения признаков на основе оценки дисперсии сигнала, спектрального анализа и анализа энтропии. Для указанных методов значения $p_{\text{дисп.}} = 0,023, p_{\text{спектр.}} = 9,973 \cdot 10^{-5}, p_{\text{энтр.}} = 0,00158$ меньше уровня значимости $\alpha = 0,05$.

В то же время, для методов выделения признаков на основе вейвлет-преобразования, модели авторегрессии и общего пространственного фильтра полученные значения $p_{\text{вейвл.}} = 0,06104, p_{\text{авторег.}} = 0,0642, p_{\text{фильтр}} = 0,438$ превышают $\alpha = 0,05$, что свидетельствует об инвариантности данных методов по отношению к предобработке ЭЭГ сигнала.

Заключение

В результате проведённых исследований показана возможность применения анализа энтропии для выделения характерных признаков сигнала ЭЭГ в приложениях ИМК, что также подтверждается другими работами в этой области [15].

В ходе сравнения данного метода с рядом других методов, получивших распространение в приложениях ИМК, установлено, что сформированные с помощью анализа энтропии признаки обладают большей информативностью, о чем свидетельствует средняя точность классификации 0,57, которая является максимальной из рассчитанных.

Однако в то же время наблюдается существенное влияние на конечный результат способа предобработки ЭЭГ сигнала.

В случаях, когда, ввиду отсутствия априорной информации о природе артефактов, затруднен выбор эффективного способа предобработки, предпочтительным является формирование вектора характерных признаков на основе вейвлет-преобразования или общего пространственного фильтра. Данные методы обеспечивают наибольшую среднюю точность классификации для исходного ЭЭГ сигнала (таблица 1).

Список литературы

1. Dornhege G., Millan J. del R., Hinterberger T., McFarland D.J., Müller K.-R., eds. Toward Brain-Computer Interfacing. A Bradford book. The MIT Press, 2007. 520 p.
2. Кропотов Ю.Д. Количественная ЭЭГ, когнитивные вызванные потенциалы мозга человека и нейротерапия. Донецк: Издатель Заславский А.Ю., 2010. 512 с.
3. Kalcher J., Pfurtscheller G. Discrimination between phase-locked and non-phase-locked event-related EEG activity // *Electroencephalography and Clinical Neurophysiology*. 1995. Vol. 94, no. 5. P. 381-384. DOI: [10.1016/0013-4694\(95\)00040-6](https://doi.org/10.1016/0013-4694(95)00040-6)
4. Pfurtscheller G., Lopes da Silva F.H. Event-related EEG/MEG synchronization and desynchronization: basic principles // *Clinical Neurophysiology*. 1999. Vol. 110, iss. 11. P. 1842-1857. DOI: [10.1016/S1388-2457\(99\)00141-8](https://doi.org/10.1016/S1388-2457(99)00141-8)
5. Xu B., Song A. Pattern Recognition of Motor Imagery EEG using Wavelet Transform // *Journal of Biomedical Science and Engineering*. 2008. Vol. 1, no. 1. P. 64-67. DOI: [10.4236/jbise.2008.11010](https://doi.org/10.4236/jbise.2008.11010)
6. Седов А.С., Раева С.Н. Применение вейвлет-анализа для исследования импульсной активности нейронов головного мозга человека // *Нейроинформатика*. 2007. Т. 2, № 1. С. 77-92.
7. Blankertz B., Tomioka R., Lemm S., Kawanabe M., Muller K.-R. Optimizing Spatial Filters for Robust EEG Single-Trial Analysis // *IEEE Signal Processing Magazine*. 2008. Vol. 25, iss. 1. P. 41-56. DOI: [10.1109/MSP.2008.4408441](https://doi.org/10.1109/MSP.2008.4408441)

8. Zhang D., Wang Y., Gao X. An Algorithm for Idle-State Detection in Motor-Imagery-Based Brain-Computer Interface // Computational Intelligence and Neuroscience. 2007. Vol. 2007. Art. no. ID 39714. DOI: [10.1155/2007/39714](https://doi.org/10.1155/2007/39714)
9. Brunner C., Billinger M., Vidaurre C., Neuper C. A comparison of univariate, vector, bilinear autoregressive, and band power features for brain-computer interfaces // Medical and Biological Engineering and Computing. 2011. Vol. 49, iss. 11. P. 1337-1346. DOI: [10.1007/s11517-011-0828-x](https://doi.org/10.1007/s11517-011-0828-x)
10. Немирко А.П., Манило Л.А., Калиниченко А.Н. Сравнительный анализ применения различных оценок энтропии ЭЭГ-сигнала для распознавания стадий наркоза // Биотехносфера. 2010. № 3. С. 3-10.
11. Oskoei M.A., Hu H. Support vector machine-based classification scheme for myoelectric control applied to upper limb // IEEE Transactions on Biomedical Engineering. 2008. Vol. 55, no. 8. P. 1956-1965. DOI: [10.1109/TBME.2008.919734](https://doi.org/10.1109/TBME.2008.919734)
12. Хайкин С. Нейронные сети: полный курс: пер. с англ. 2-е изд. М.: Издательский дом «Вильямс», 2006. 1104 с.
13. Chen P.H., Lin C.J., Scholkopf B. A tutorial on v-support vector machines // Applied Stochastic Models in Business and Industry. 2005. Vol. 21, iss. 2. P. 111-136. DOI: [10.1002/asmb.537](https://doi.org/10.1002/asmb.537)
14. Brunner C., Leeb R., Müller-Putz G., Schlögl A., Pfurtscheller G. BCI Competition 2008 - Graz data set A // BBCI: Berlin Brain-Computer Interface: website. Режим доступа: <http://www.bbc.de/competition/iv/> (дата обращения 01.08.2014).
15. Fang Y., Chen M., Zheng X. Feature Extraction of Motor Imagery in BCI with Approximate Entropy // Journal of Computational Information Systems. 2012. Vol. 8, no. 6. P. 2485-2491.

Entropy Analysis as an Electroencephalogram Feature Extraction Method

P.I. Sotnikov^{1,*}

^{*}sotnikoffp@gmail.com

¹Bauman Moscow State Technical University, Moscow, Russia

Keywords: brain-computer interfaces (BCI), electroencephalogram (EEG) analysis, entropy analysis, Shannon entropy, nu- support vector machines (nu-SVM)

The aim of this study was to evaluate a possibility for using an entropy analysis as an electroencephalogram (EEG) feature extraction method in brain-computer interfaces (BCI). The first section of the article describes the proposed algorithm based on the characteristic features calculation using the Shannon entropy analysis. The second section discusses issues of the classifier development for the EEG records. We use a support vector machine (SVM) as a classifier. The third section describes the test data. Further, we estimate an efficiency of the considered feature extraction method to compare it with a number of other methods. These methods include: evaluation of signal variance; estimation of spectral power density (PSD); estimation of autoregression model parameters; signal analysis using the continuous wavelet transform; construction of common spatial pattern (CSP) filter. As a measure of efficiency we use the probability value of correctly recognized types of imagery movements. At the last stage we evaluate the impact of EEG signal preprocessing methods on the final classification accuracy. Finally, it concludes that the entropy analysis has good prospects in BCI applications.

References

1. Dornhege G., Millan J. del R., Hinterberger T., McFarland D.J., Müller K.-R., eds. *Toward Brain-Computer Interfacing*. The MIT Press, 2007. 520 p.
2. Kropotov Yu.D. *Kolichestvennaya EEG, kognitivnye vyzvannye potentsialy mozga cheloveka i neyroterapiya* [Quantitative EEG, cognitive evoked potentials of the human brain and neurotherapy]. Donetsk, Publisher Zaslavskiy A.Yu., 2010. 512 p. (in Russian).
3. Kalcher J., Pfurtscheller G. Discrimination between phase-locked and non-phase-locked event-related EEG activity. *Electroencephalography and Clinical Neurophysiology*, 1995, vol. 94, no. 5, pp. 381-384. DOI: [10.1016/0013-4694\(95\)00040-6](https://doi.org/10.1016/0013-4694(95)00040-6)

4. Pfurtscheller G., Lopes da Silva F.H. Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 1999, vol. 110, iss. 11, pp. 1842-1857. DOI: [10.1016/S1388-2457\(99\)00141-8](https://doi.org/10.1016/S1388-2457(99)00141-8)
5. Xu B., Song A. Pattern Recognition of Motor Imagery EEG using Wavelet Transform. *Journal of Biomedical Science and Engineering*, 2008, vol. 1, no. 1, pp. 64-67. DOI: [10.4236/jbise.2008.11010](https://doi.org/10.4236/jbise.2008.11010)
6. Sedov A.S., Raeva S.N. Application of wavelet analysis for the study of impulse activity of neurons of the human brain. *Neyroinformatika*, 2007, vol. 2, no. 1, pp. 77-92. (in Russian).
7. Blankertz B., Tomioka R., Lemm S., Kawanabe M., Muller K.-R. Optimizing Spatial Filters for Robust EEG Single-Trial Analysis. *IEEE Signal Processing Magazine*, 2008, vol. 25, iss. 1, pp. 41-56. DOI: [10.1109/MSP.2008.4408441](https://doi.org/10.1109/MSP.2008.4408441)
8. Zhang D., Wang Y., Gao X. An Algorithm for Idle-State Detection in Motor-Imagery-Based Brain-Computer Interface. *Computational Intelligence and Neuroscience*, 2007, vol. 2007, art. no. ID 39714. DOI: [10.1155/2007/39714](https://doi.org/10.1155/2007/39714)
9. Brunner C., Billinger M., Vidaurre C., Neuper C. A comparison of univariate, vector, bilinear autoregressive, and band power features for brain-computer interfaces. *Medical and Biological Engineering and Computing*, 2011, vol. 49, iss. 11, pp. 1337-1346. DOI: [10.1007/s11517-011-0828-x](https://doi.org/10.1007/s11517-011-0828-x)
10. Nemirko A.P., Manilo L.A., Kalinichenko A.N. Comparative analysis of the use of different estimates of the entropy of EEG signal for recognition of stages of anesthesia. *Biotekhnosfera*, 2010, no. 3, pp. 3-10. (in Russian).
11. Oskoei M.A., Hu H. Support vector machine-based classification scheme for myoelectric control applied to upper limb. *IEEE Transactions on Biomedical Engineering*, 2008, vol. 55, no. 8, pp. 1956-1965. DOI: [10.1109/TBME.2008.919734](https://doi.org/10.1109/TBME.2008.919734)
12. Haykin S. *Neural networks: A comprehensive foundation*. 2nd ed. Englewood Cliffs, Prentice-Hall, 1998. 842 p. (Russ. ed.: Haykin S. *Neironnye seti: polnyi kurs*. Moscow, Vil'iams Publ., 2006, 1104 p.).
13. Chen P.H., Lin C.J., Scholkopf B. A tutorial on v-support vector machines. *Applied Stochastic Models in Business and Industry*, 2005, vol. 21, iss. 2, pp. 111-136. DOI: [10.1002/asmb.537](https://doi.org/10.1002/asmb.537)
14. Brunner C., Leeb R., Müller-Putz G., Schlögl A., Pfurtscheller G. *BCI Competition 2008 - Graz data set A*. BBCI: Berlin Brain-Computer Interface: website. Available at: <http://www.bbci.de/competition/iv/> , accessed 01.08.2014).

15. Fang Y., Chen M., Zheng X. Feature Extraction of Motor Imagery in BCI with Approximate Entropy. *Journal of Computational Information Systems*, 2012, vol. 8, no. 6, pp. 2485-2491.