Наука и Образование
МГТУ им. Н.Э. Баумана
Сетевое научное издание
ISSN 1994-0408

Наука и Образование. МГТУ им. Н.Э. Баумана. Электрон. журн. 2015. № 06. С. 217–234.

DOI: **10.7463/0615.0778091**

Представлена в редакцию: 15.05.2015

© МГТУ им. Н.Э. Баумана

УДК 004.5

Выбор оптимальных частотных диапазонов сигнала электроэнцефалограммы в интерфейсе мозг-компьютер

Сотников П. И.[1,*]

*sotnikoffp@gmail.com

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

В работе предлагается новый метод обработки сигнала электроэнцефалограммы (ЭЭГ) в интерфейсах мозг-компьютер (ИМК), основанных на анализе сенсомоторных ритмов. Идея метода заключается в автоматическом выборе наиболее информативных частотных диапазонов сигнала ЭЭГ. Данный подход позволяет повысить точность классификации в ИМК благодаря учету индивидуальных особенностей пользователей интерфейса. Задача поиска частотных диапазонов рассматривается, как задача однокритериальной оптимизации, в которой в качестве варьируемых параметров выступают границы частотных диапазонов, а в качестве целевой функции - оценка достижимой точности классификации. Решение поставленной задачи предлагается искать с помощью генетического алгоритма. На тестовых данных, предоставленных для проведения соревнования «BCI Competition IV», выполняется сравнение эффективности предлагаемого метода с рядом других методов.

Ключевые слова: интерфейс мозг-компьютер (ИМК), анализ электроэнцефалограмм (ЭЭГ), выбор частотных диапазонов, генетический алгоритм

Введение

Интерфейс мозг-компьютер (ИМК) (англ. *Brain-Computer Interface, BCI*) является новой системой коммуникации человека с машиной (например, с компьютером или протезом), основанной на преобразовании регистрируемой активности мозга в управляющие команды внешнему техническому устройству.

Одним из типов *неинвазивных* интерфейсов мозг-компьютер, 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 путем мысленного представления того или иного движения. В частности, при управлении виртуальной машиной пользователь может представлять движения левой или правой руки для имитации поворота руля, а движения ног – для имитации нажатий на педали.

Любой ИМК реализует следующие стадии обработки нейрофизиологических данных: регистрация и оцифровка сигнала ЭЭГ; предобработка (фильтрация от шумов, удаление артефактов); выделение характерных признаков; классификация полученных признаков.

В большинстве работ для всех испытуемых сигнал ЭЭГ анализируется в классических частотных диапазонах, заимствованных из клинической практики: 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) [1,2]. Однако характеристики сигнала ЭЭГ могут в значительной степени различаться между испытуемыми, что может оказывать влияние на точность правильного распознавания типов воображаемых движений.

Для учета вариативности параметров сенсомоторных ритмов в публикациях был предложен ряд методов, позволяющих выбирать наиболее информативные, с точки зрения разделения классов, частотные диапазоны ЭЭГ. Как правило, данные методы являются модификациями общего пространственного фильтра (англ. *Common Spatial Pattern Filter - CSP*). В частности, в работах победителей соревнования «*BCI Competition IV*» используется подход, основанный на применении блока частотных фильтров (англ. *Filter Bank*) с последующей пространственной фильтрацией сигнала на выходе каждого элемента блока [3,4]. Метод является сравнительно простым в реализации, однако параметры частотных фильтров (границы диапазонов) необходимо задавать заранее, до обработки записей ЭЭГ.

В работе [5] был предложен метод адаптивной частотно-пространственной фильтрации сигнала (англ. *Adaptively Weighted Spectral-Spatial Patterns - AWSSP*). На первом шаге алгоритма с помощью оконного преобразования Фурье (англ. *Short-Time Fourier Transform - STFT*) рассчитывается функция изменения спектральной плотности мощности сигнала с течением времени. Каждая такая функция (матрица *STFT*-преобразования) в соответствии с обучающей выборкой относится к одному из классов. Далее на итерациях алгоритма осуществляется попытка выделить такие частотные диапазоны, для которых было бы максимальным значение критерия Фишера (англ. *Fisher`s ratio*), определяющего для матриц *STFT*-преобразования отношение межклассовой дисперсии к внутриклассовой.

В работе [6] рассматривается алгоритм поиска информативных частотных диапазонов сигнала ЭЭГ на основе карт вызванной синхронизации (англ. *event-related synchronization - ERS*) и десинхронизации (англ. *event-related desynchronization - ERD*) сенсомоторных ритмов. На данных картах, построенных для каждого канала записи ЭЭГ, отображаются связанные с представлением движений различия в мощности сигнала на разных частотах. Для нахождения информативных частотных диапазонов с помощью полученных карт в работе использовались методы машинного зрения, позволяющие выделять связные области на картах.

В настоящей работе предлагается новый метод автоматического поиска наиболее информативных частотных диапазонов сигнала ЭЭГ. Критерием информативности

служит точность разделения классов воображаемых движений. Задача поиска частотных диапазонов рассматривается, как задача *однокритериальной оптимизации*, в которой в качестве варьируемых параметров выступают границы частотных диапазонов, а в качестве целевой функции - оценка достижимой точности классификации. Решение поставленной задачи предлагается искать с помощью *генетического алгоритма*.

В первом разделе статьи на реальных данных, описание которых представлено в Приложении А, исследуются различия в характеристиках сенсомоторных ритмов ЭЭГ между испытуемыми. Во втором разделе приводится математическая постановка задачи поиска оптимальных частотных диапазонов сигнала ЭЭГ. В третьем разделе рассматривается применение генетического алгоритма для решения поставленной задачи. В четвертом разделе на реальных данных ЭЭГ выполняется сравнение эффективности предлагаемого метода с рядом других методов. В заключении формулируются основные результаты работы и направления дальнейших исследований.

1. Исследование вариативности параметров сенсомоторных ритмов

Известно, что выполнение человеком движений или их мысленное представление сопровождается состояниями *синхронизации* и *десинхронизации* сенсомоторных ритмов (англ. *sensorimotor rhythms - SMR*) [7]. При этом наиболее выраженно данные состояния проявляются в диапазоне частот от 7 до 12 Гц, который соответствует так называемому *мю-ритму* на ЭЭГ. Отметим, что параметры *мю-ритма* могут в значительной степени варьироваться в зависимости от индивидуальных особенностей испытуемых. В частности, варьируется диапазон частот сигнала ЭЭГ, на которых в большей степени проявляются отличия между разными типами воображаемых движений.

Для иллюстрации описанного явления воспользуемся тестовыми данными, рассмотренными в Приложении А.

Для всех проб, полученные в двух сессиях без обратной связи и первой сессии с обратной связью, было выполнено непрерывное вейвлет-преобразование сигнала (англ. *Continuous Wavelet Transform*) в каждом из каналов записи ЭЭГ (C3, Cz, C4). Далее для оценки энергии сигнала была сформирована матрица квадратов коэффициентов вейвлет-разложения. Путем усреднения элементов матрицы по строкам (то есть по оси временного сдвига) для каждого из каналов был получен энергетический спектр сигнала.

На следующем шаге было выполнено усреднение энергетических спектров по всем обучающим записям ЭЭГ для каждого из классов в отдельности. Для выявления различий между классами была рассчитана разность полученных спектров.

На рисунке 1 на примере четырех испытуемых B01-B04 представлены графики разности между полученными усредненными энергетическими спектрами. Различные кривые на графиках соответствуют разным каналам записи ЭЭГ.

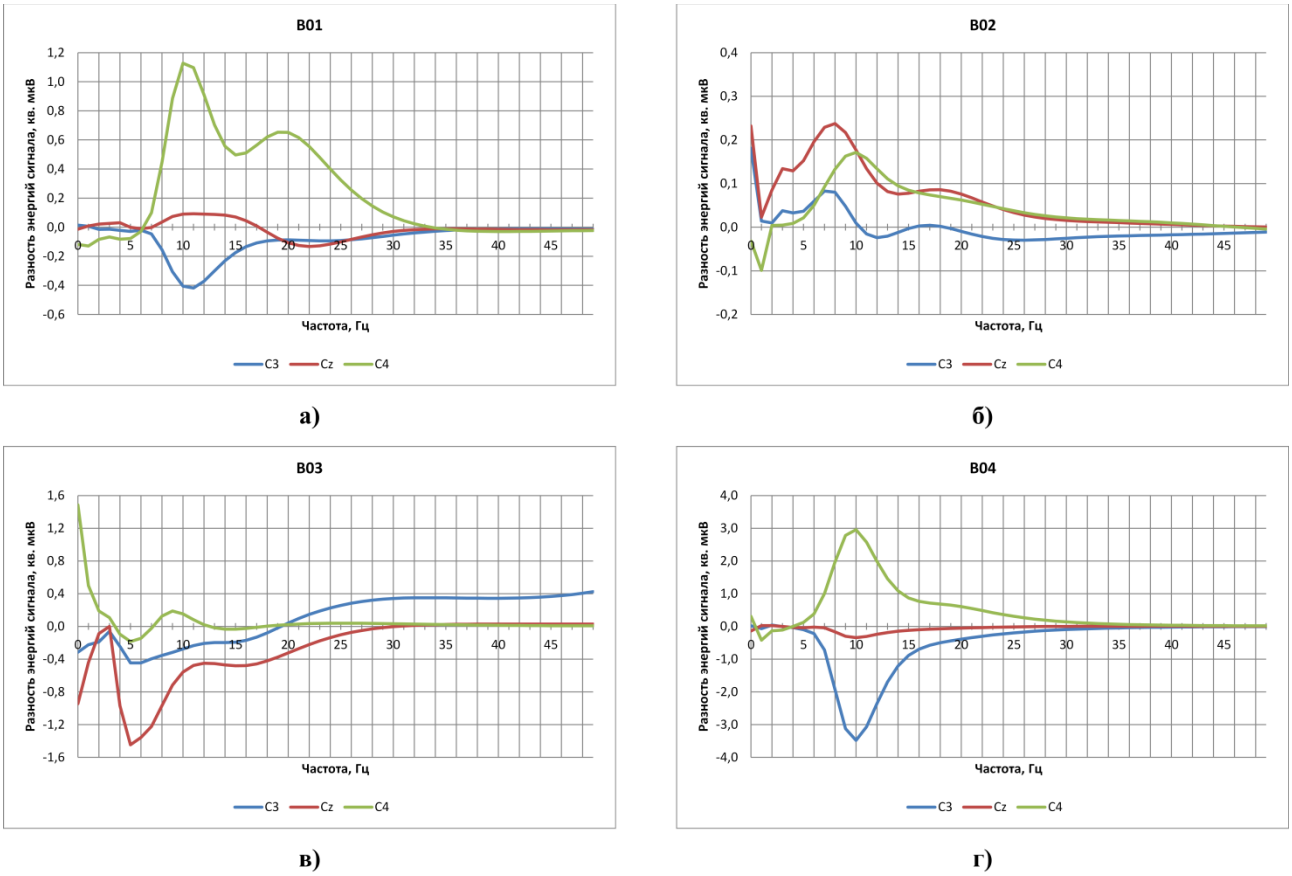

Рис. 1. Различия между двумя классами воображаемых движений на примере разности усредненных энергетических спектров.

Как следует из рисунка 1, между испытуемыми наблюдаются существенные различия в картине разности усредненных энергетических спектров. В области *мю-ритма* (7-12 Гц) выраженные пики на графиках присутствуют только для испытуемых B01 и B04. Однако для испытуемого B01 наблюдается дополнительный пик в области частот 15-22 Гц. Для испытуемых B02 и B03 в области *мю-ритма* различия между классами проявлены в меньшей степени, при этом в разных каналах записи ЭЭГ пики на графиках приходятся на разные частоты.

Таким образом, для увеличения производительности интерфейсов мозг-компьютер, анализ сигнала ЭЭГ, вместо классических частотных диапазонов, целесообразно проводить в частотных диапазонах, границы которых определяются индивидуально для каждого из испытуемых. В данной работе для каждого из каналов записи ЭЭГ предлагается искать по одному оптимальному частотному диапазону.

2. Постановка задачи поиска оптимальных частотных диапазонов сигнала ЭЭГ

Пусть имеется исходный набор данных $\Omega = \{\mathbf{X}_i, k_i\}_{i=1}^{P}$ объема P, где $\mathbf{X}_i$ – i-тая запись сигнала ЭЭГ, а $k_i \in \{1,2,\dots,K\}$ – метка класса, соответствующая одному из K типов распознаваемых движений.

Примем, что каждая запись сигнала ЭЭГ $\mathbf{X}_i \in \mathbb{R}^{M\times N}, i = \overline{1,P}$ 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 $t = \overline{0,(N-1)\Delta t}$, где N – общее число отсчетов, Δt – интервал дискретизации.

В задачах классификации обычно осуществляется переход от многомерного временного ряда, описывающего сигнал, к некоторому вектору признаков, характеризующему этот временной ряд.

Введем оператор Φ, который в зависимости от заданных границ частотных диапазонов будет выполнять отображение исходного сигнала $\mathbf{X}_i, i = \overline{1,P}$ в пространство характерных признаков.

Как показано выше, параметры сенсомоторных ритмов, отвечающие за разделение классов воображаемых движений, могут варьироваться как между испытуемыми, так и между отдельными каналами записи ЭЭГ. В связи с этим, для каждого из каналов, представленных в записи, будем искать свой частотный диапазон $[f_1; f_2]$, где $f_1, f_2 \in \mathbb{Z}$ - начальная и конечная границы диапазона соответственно.

Для определения границ диапазонов во всех M отведениях введем векторы $F_1 = (f_{1,1}, f_{1,2}, \dots, f_{1,M})^T, F_2 = (f_{2,1}, f_{2,2}, \dots, f_{2,M})^T$ размерности $M \times 1$. На рисунке 2 изображен пример выбора частотных диапазонов в зависимости от заданных компонентов векторов F_1, F_2.

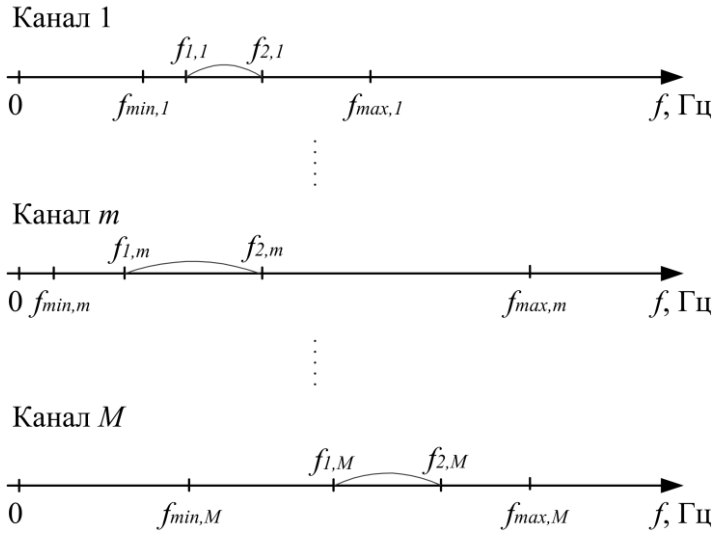

Рис. 2. Выбор границ частотных диапазонов для многоканального сигнала ЭЭГ.

С учетом принятых обозначений, выражение для расчета векторов характерных признаков можно записать в виде

$$V_i(F_1, F_2) = \Phi(\mathbf{X}_i, F_1, F_2), V_i \in \mathbb{R}^{L\times 1}, i = \overline{1,P},$$

где $V_i(F_1, F_2)$ – вектор характерных признаков для i-той записи сигнала ЭЭГ; L – размерность данного вектора. В общем случае $L \neq M$.

Выполнив для всех записей ЭЭГ замену исходного многомерного сигнала $\mathbf{X}_i$ его признаковым описанием $V_i(F_1, F_2)$, перейдем от заданного множества $\Omega = \{\mathbf{X}_i, k_i\}_{i=1}^{P}$ к новому множеству $\Upsilon(F_1, F_2) = \{V_i(F_1, F_2),\ k_i\}_{i=1}^{P}$.

Через $\varphi(F_1, F_2)$ обозначим скалярную функцию, являющуюся некоторой оценкой точности классификации, достижимой на множестве $\Upsilon(F_1, F_2)$. Здесь и далее под точностью классификации будем понимать вероятность правильного распознавания типов воображаемых движений с помощью какого-либо классификатора.

Тогда задачу автоматического поиска наиболее информативных частотных диапазонов сигнала ЭЭГ можно свести к следующей задаче однокритериальной условной глобальной оптимизации

$$\max_{F_1, F_2 \in D_F} \varphi(F_1, F_2) = \varphi(F_1^*, F_2^*) = \varphi^*,$$

$$D_F = \{F_{min} \le F_1 \le F_2 \le F_{max}\},\ D_F \subset \mathbb{Z}^{M \times 1}.$$

Здесь F_1, F_2 – варьируемые параметры; F_{min}, F_{max} – векторы, определяющие нижние и верхние допустимые границы частотных диапазонов соответственно. В общем случае для каждого из каналов могут быть заданы свои допустимые границы, как это показано на рисунке 2.

Для решения поставленной задачи можно воспользоваться различными методами поисковой оптимизации. В данной работе рассмотрим применение генетического алгоритма.

3. Применение генетического алгоритма для нахождения оптимальных частотных диапазонов сигнала ЭЭГ

3.1. Выделение характерных признаков сигнала ЭЭГ

На первом этапе определим оператор, сопоставляющий каждой записи сигнала ЭЭГ вектор характерных признаков.

Для анализа сигнала ЭЭГ в частотной области воспользуемся *непрерывным вейвлет-преобразованием* (НВП), которое позволяет отследить динамику изменения гармонических составляющих сигнала с течением времени [8].

Расчет коэффициентов вейвлет-разложения будем производить в узлах некоторой дискретной сетки, заданной на плоскости *(a,τ)*, где a, τ – параметры масштаба и временного сдвига соответственно. Через N_a обозначим разрешение сетки по оси масштаба, а через N_τ – разрешение сетки по оси временного сдвига.

Величину шага вдоль оси τ выберем равномерной, а значения масштабов a_i примем обратно пропорциональными исследуемым частотам, согласно выражению

$$a_i = \frac{\omega_0}{2\pi f_i}.$$

Здесь ω_0 – центральная частота материнского вейвлета; $f_i = (i+1)\Delta h_f$ - значения центральных частот дочерних вейвлетов в узлах сетки с индексами $i = 0,1,\dots,N_a - 1$; Δh_f – шаг по частоте (в Гц). Для упрощения дальнейших вычислений примем $\Delta h_f = 1$ Гц.

С учетом введенных обозначений, для одномерного сигнала $x(t)$, представленного в виде последовательности отсчетов, взятых в моменты времени $t = n\Delta t, n = \overline{0, N-1}$,

элементы матрицы коэффициентов вейвлет-разложения $\mathbf{W} = \{w_{ij}\}$ можно определить по формуле

$$w_{ij} = \sum_{t=0}^{(N-1)\Delta t} x(t) \cdot \Psi^*\left(\frac{t-\tau_j}{a_i}\right), i = 0,1,\dots,N_a - 1;\ j = 0,1,\dots,N_\tau - 1\ ,$$

где $\Psi(t)$ – материнская вейвлет-функция; «*» означает оператор комплексного сопряжения; a_i и τ_j – значения масштаба и временного сдвига в узле сетки с номером (i,j); Δt – интервал дискретизации, N – общее число отсчетов сигнала.

Для оценки энергии сигнала в каждом из каналов $m \in \{1,2,\dots,M\}$ воспользуемся матрицей квадратов коэффициентов вейвлет-разложения $\mathbf{E}_m = \{{w_{ij}}^2\}$ размерности $N_a \times N_\tau$.

За период времени, в течение которого проводилась запись ЭЭГ, средние значения энергии сигнала на каждой из гармоник можно рассчитать по формуле

$$E_m(i) = \frac{1}{N_\tau} \sum_{j=0}^{N_\tau - 1} e_m(i,j)\,, i = 0,1,\dots,N_a - 1,\ m = 1,2,\dots,M.$$

Здесь $e_m(i,j)$ – элемент матрицы $\mathbf{E}_m$ в позиции с номером (i,j); $E_m(i)$ – среднее значение элементов матрицы $\mathbf{E}_m$ в строке с индексом i.

Совокупность величин $E_m(i),\ i = \overline{0, N_a - 1}$ можно интерпретировать, как энергетический спектр сигнала, который обозначим как $E_m(f)$.

На рисунке 3 представлен пример расчёта для сигнала ЭЭГ матрицы квадратов коэффициентов вейвлет-разложения $\mathbf{E}_m$ и усредненного энергетического спектра $E_m(f)$.

Каждому каналу записи ЭЭГ сопоставим один характерный признак $v_m(f_{1,m}, f_{2,m})$, значение которого будем рассчитывать, как площадь фигуры под графиком энергетического спектра на отрезке $[f_{1,m}; f_{2,m}]$ (рисунок 3*в*). С учетом того, что шаг по частоте Δh_f был выбран равномерным, приближенное значение площади фигуры можно найти по методу трапеций

$$v_m(f_{1,m}, f_{2,m}) = \frac{\Delta h_f}{2}\left[E_m(f_{1,m}) + E_m(f_{2,m})\right] + \Delta h_f \cdot \sum_{i=f_{1,m}+1}^{f_{2,m}-1} E_m(i)\,, m = 1,2,\dots,M,$$

где $f_{1,m}$ и $f_{2,m}$ – соответственно начальная и конечная границы частотного диапазона, заданные для канала с номером m.

В итоговый вектор V включим значения характерных признаков, полученные для каждого из каналов

$$V(F_1, F_2) = \left(v_1(f_{1,1}, f_{2,1}), \dots, v_M(f_{1,M}, f_{2,M})\right)^T.$$

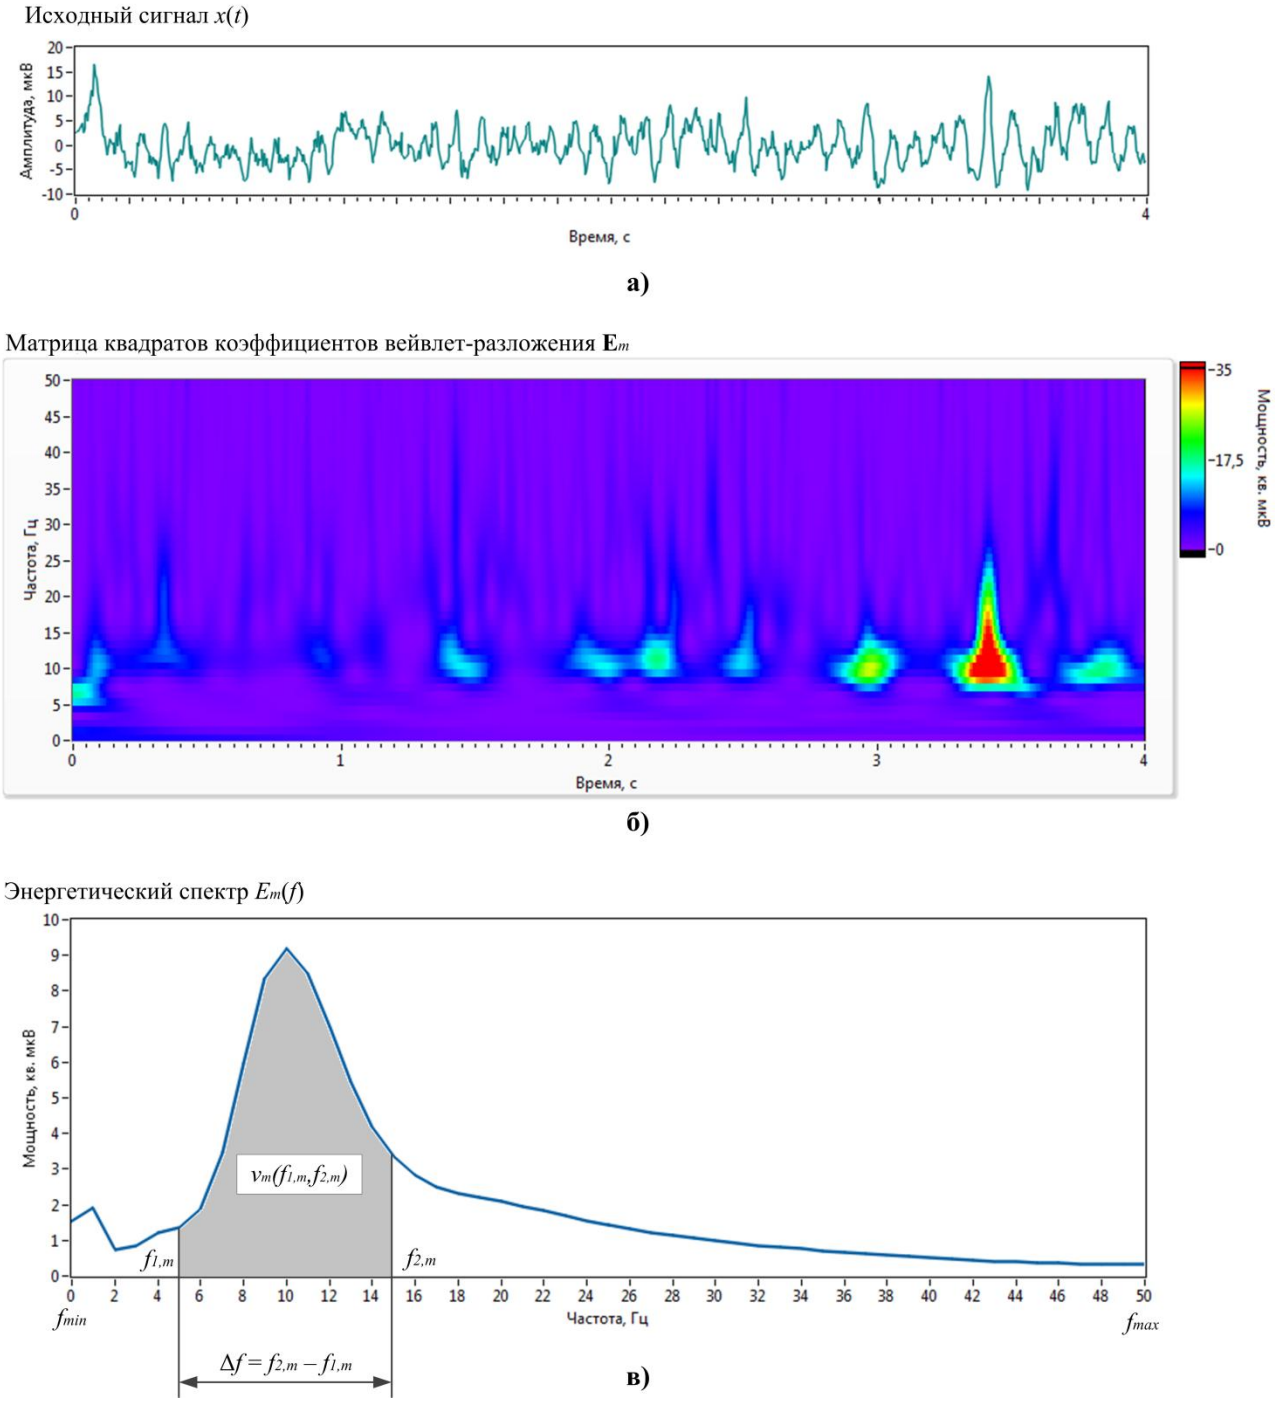

Рис. 3. Пример расчета энергетического спектра для сигнала ЭЭГ: а) Исходный сигнал $x(t)$; б) Матрица квадратов коэффициентов вейвлет-разложения $\mathbf{E}_m$; в) Энергетический спектр $E_m(f)$, усредненный за время записи ЭЭГ.

Общая последовательность операций, необходимых для вычисления вектора характерных признаков, показана на рисунке 4.

Отметим, что для нахождения энергетического спектра сигнала можно также воспользоваться дискретным преобразованием Фурье, которое требует меньших вычислительных затрат. Однако с учетом нестационарности сигнала ЭЭГ, применение вейвлет-преобразования является более предпочтительным.

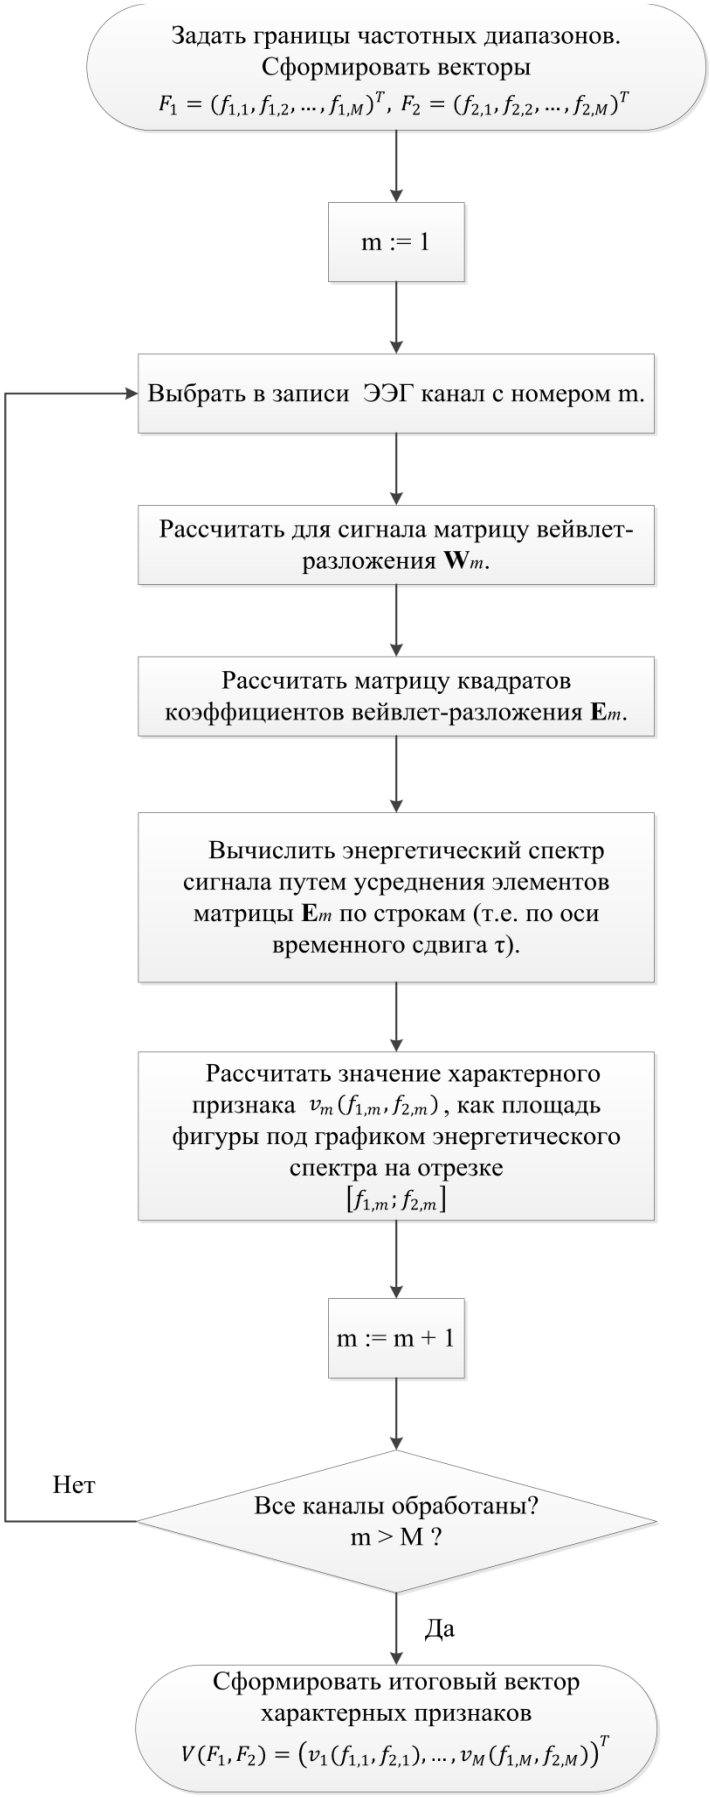

Рис. 4. Блок-схема алгоритма расчета характерных признаков сигнала ЭЭГ.

3.2. Схема используемого генетического алгоритма

Особей s популяции определим следующим образом

$$s = \langle F_1, F_2, H, \varphi(F_1, F_2) \rangle,$$

где векторы F_1, F_2 задают фенотип особи, H – её генотип, $\varphi(F_1, F_2)$ - приспособленность данной особи.

Для кодирования значений варьируемых параметров F_1, F_2 воспользуемся представлением генотипа в виде монохромосомы $H = [(h_{1,1}, h_{2,1}); \dots; (h_{1,m}, h_{2,m}); \dots; (h_{1,M}, h_{2,M})]$, где через $h_{1,m}, h_{2,m}$ обозначены гены, отвечающие за кодирование элементов векторов F_1 и F_2 с индексами $m = 1,2, \dots, M$.

Примем, что гены $h_{1,1}, h_{1,2}, \dots, h_{1,M}$ являются r-разрядными двоичными представлениями чисел $f_{1,1}, f_{1,2}, \dots, f_{1,M}$, задающих начальные границы частотных диапазонов, а гены $h_{2,1}, h_{2,2} \dots, h_{2,M}$ – r-разрядными представлениями чисел $f_{2,1}, f_{2,2}, \dots, f_{2,M}$, определяющих конечные границы. Общая размерность хромосомы H, таким образом, составляет $2M$.

Разделим исходный набор $\Omega = \{\mathbf{X}_i, k_i\}_{i=1}^{P}$ данных на три непересекающихся подмножества, в общем случае, различного объема. Данные подмножества будем использовать в качестве *обучающей*, *тестовой* и *валидационной* выборки.

Для каждой из особей s значение функции приспособленности $\varphi(F_1, F_2)$ будем вычислять следующим образом.

1) В соответствии с алгоритмом, приведенным на рисунке 3, для всех записей ЭЭГ, входящих в состав *обучающей* и *тестовой* выборки, в зависимости от варьируемых параметров F_1, F_2 рассчитываются значения компонентов векторов характерных признаков.
2) На множестве пар, сформированных векторами характерных признаков, полученными для *обучающей* выборки, и соответствующими им метками классов, производится построение классификатора. На векторах, полученных для *тестовой* выборки, выполняется оценка точности классификации.
3) Рассчитанная точность классификации принимается в качестве значения функции приспособленности.

На начальном шаге генетического алгоритма происходит создание исходной популяции особей, для которых компоненты векторов F_1, F_2 задаются случайным образом. Далее особи оцениваются и сортируются по значению функции приспособленности $\varphi(F_1, F_2)$. Отбор родительских пар производится *по методу «рулетки»* [9]. На следующем шаге с равной вероятностью выполняется *одноточечный* или *двухточечный кроссовер* (скрещивание), для каждой пары родителей формируются два потомка. Далее потомки с заданной при инициализации алгоритма вероятностью подвергается мутациям. При этом применяется *оператор равномерной генной мутации*. На следующем шаге для потомков выполняется декодирование хромосом, и, если параметры F_1, F_2 лежат в допустимых границах, оценивается значение функции приспособленности. Новые особи включаются в популяцию на место наименее приспособленных.

После окончания алгоритма выбирается особь с наибольшим значением функции приспособленности φ^* и фиксируются итоговые значения варьируемых параметров F_1^*, F_2^*. Далее для них оценивается точность классификации на *валидационной* выборке, что служит для проверки обобщающих свойств метода. Полученная на *валидационной* выборке оценка принимается в качестве итогового значения точности классификации.

3. Результаты экспериментальных исследований

Экспериментальные исследования проводились на данных, описание которых представлено в Приложении А.

Для каждого из испытуемых B01-B09 записи ЭЭГ, зарегистрированные в двух сессиях без обратной связи и в первой сессии с обратной связью, были случайным образом разделены на *обучающую* и *тестовую* выборку (в отношении 3:1). В *валидационную* выборку вошли все записи ЭЭГ, полученные в последних двух сессиях с обратной связью.

В работе использовались следующие параметры генетического алгоритма:

- кодирование генов с помощью 5-разрядных двоичных чисел;
- размер популяции – 20 особей;
- число поколений – 10;
- вероятность мутации – 0,05;
- кроссовер одноточечный или двухточечный с равной вероятностью.

Для оценки приспособленности особей использовался классификатор на основе *метода опорных векторов* (англ. *Support Vector Machine - SVM*). В частности, применялся вариант данного метода под названием «*nu-SVM*» [10], допускающий ошибки на обучающей выборке.

Точность «*nu-SVM*» классификатора (которую обозначим как $\alpha(\nu)$) зависит от варьируемого параметра $\nu \in [0,1]$, задающего верхнюю границу доли ошибок обучения и нижнюю границу числа опорных векторов. В связи с этим для всех особей s, входящих в состав популяции, значение ν изменялось в диапазоне от 0,1 до 0,95 с шагом 0,05. Для каждого из указанных значений ν выполнялось обучение и тестирование «*nu-SVM*» классификатора. Среди полученных значений $\alpha(\nu)$ выбиралось максимальное, которое затем принималось в качестве оценки функции приспособленности $\varphi(F_1, F_2)$ для данной особи.

В работе использовалось сочетание генетического алгоритма с *методом мультистарта*. Для всех испытуемых B01-B09 было выполнено по 5 запусков генетического алгоритма. После завершения каждой итерации значение точности классификации оценивалось на *валидационной* выборке. По результатам работы метода мультистарта в качестве итогового значения точности классификации было выбрано максимальное из полученных.

Результаты экспериментов обобщены в таблице 1. В первой строке таблицы представлены значения точности классификации, достижимые на векторах характерных признаков, сформированных с помощью НВП для классических частотных диапазонов

(подробно метод описан в [11]). Во второй строке приведены оценки точности классификации, полученные по результатам работы генетического алгоритма в сочетании с методом мультистарта.

Таблица 1. Оценки точности классификации.

	Номер испытуемого									**Среднее значение**
	B01	**B02**	**B03**	**B04**	**B05**	**B06**	**B07**	**B08**	**B09**	
НВП (классические диапазоны)	0,73	0,57	0,59	0,96	0,77	0,84	0,72	0,88	0,82	**0,76**
НВП (оптимальный диапазон)	0,84	0,65	0,66	0,98	0,95	0,90	0,76	0,93	0,85	**0,83**

Для сравнения также приведем результаты, полученные с помощью метода, предложенного победителем соревнования «*BCI Competition IV*» [12].

Для победителя соревнования оценки точности классификации на рассматриваемых нами тестовых данных представлены в виде значений каппы Коэна [13], которая определяет степень согласованности между двумя категориальными переменными (оценщиками) и рассчитывается по формуле

$$kappa = \frac{Pr(a) - Pr(e)}{1 - Pr\ (e)},$$

где *Pr(a)* – наблюдаемая согласованность между переменными, *Pr(e)* – ожидаемая вероятность случайной согласованности.

В данном случае в качестве значений первой категориальной переменной выступают фактические метки классов, а в качестве значений второй переменной – метки, присвоенные классификатором. Таким образом, величину *Pr(a)* можно трактовать как вероятность правильного распознавания классов, а величину *Pr(e)* – как вероятность случайной классификации.

При известных значениях каппы Коэна оценку точности классификации можно получить, воспользовавшись формулой

$$Pr(a) = Pr(e) + kappa \cdot (1 - Pr(e)).$$

Здесь для двух типов воображаемых движений вероятность случайной классификации *Pr(e)* составляет 50%.

В таблице 2 представлены значения каппы Коэна и восстановленные значения точности классификации для победителя соревнования «*BCI Competition IV*».

Таблица 2. Результаты победителя соревнования.

	Номер испытуемого									**Среднее значение**
	B01	**B02**	**B03**	**B04**	**B05**	**B06**	**B07**	**B08**	**B09**	
Каппа Коэна	0,40	0,21	0,22	0,95	0,86	0,61	0,56	0,85	0,74	**0,60**
Точность классификации	0,70	0,61	0,61	0,98	0,93	0,81	0,78	0,93	0,87	**0,80**

В графической форме результаты исследования приведены на рисунке 5.

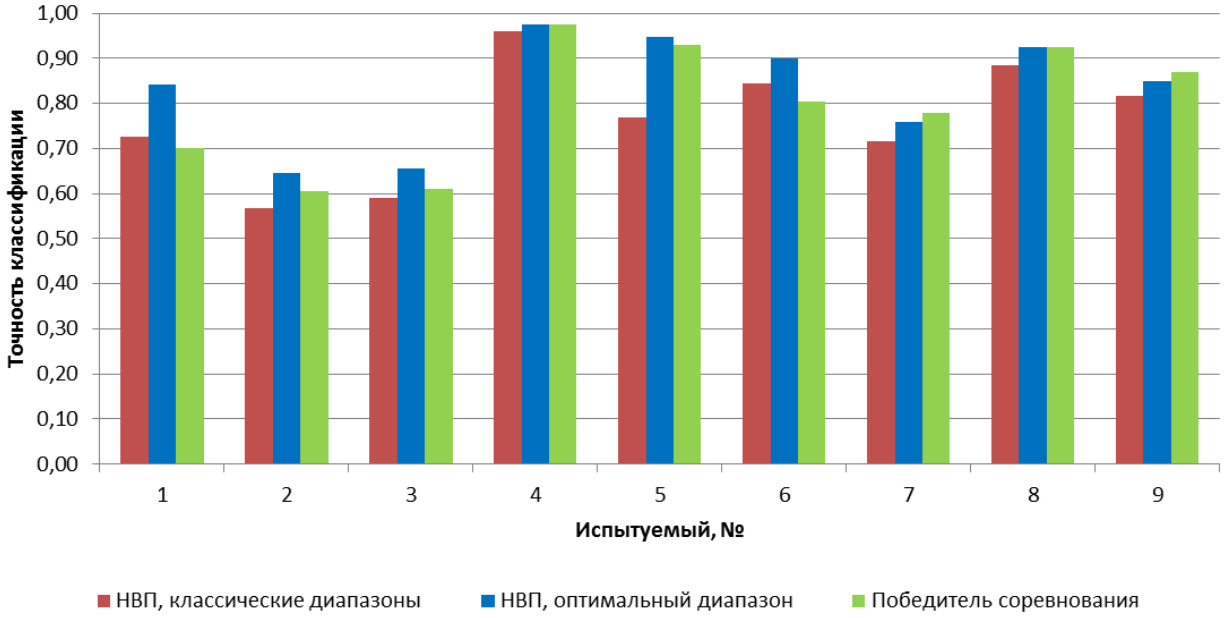

Рис. 5. Полученные оценки точности классификации.

Эффективность алгоритмов, предложенных в работах [5,6], также оценивалась на тестовых данных, предоставленных для соревнования «*BCI Competition IV*». В работе [5] для испытуемых B01-B09 средняя точность классификации составляет 74%, а в работе [6] – 72%.

Таким образом, предлагаемый подход, основанный на выборе наиболее информативных частотных диапазонов сигнала ЭЭГ с помощью генетического алгоритма, показывает наилучшую эффективность. Средняя точность классификации составляет 83%.

В таблице 3 для испытуемых B01-B09 приведены полученные на выходе генетического алгоритма значения границ оптимальных, с точки зрения разделения классов, частотных диапазонов.

Таблица 3. Границы оптимальных частотных диапазонов (в Гц).

	Номер испытуемого								
	B01	**B02**	**B03**	**B04**	**B05**	**B06**	**B07**	**B08**	**B09**
Канал C3	11 – 23	31 – 50	3 – 4	6 – 23	27 – 29	9 – 11	10 – 20	7 – 20	9 – 16
Канал Cz	18 – 47	8 - 23	21 – 28	10 – 32	5 – 17	6 – 15	26 – 30	26 – 40	18 – 19
Канал C4	5 – 29	6 – 30	23 – 28	8 – 16	30 – 37	11 – 13	11 – 16	11 – 16	10 – 26

Как видно из полученных результатов, после выбора оптимальных частотных диапазонов сигнала ЭЭГ с помощью генетического алгоритма наблюдается увеличение

точности классификации для всех испытуемых (таблица 1). Кроме того предлагаемый метод является наиболее эффективным по сравнению с другими подходами, предназначенными для учета индивидуальных особенностей испытуемых.

Заключение

В работе поставлена задача поиска оптимальных частотных диапазонов сигнала ЭЭГ в интерфейсах мозг-компьютер. Предложен метод решения поставленной задачи, который включает анализ сигнала ЭЭГ с помощью непрерывного вейвлет-преобразования с последующим применением генетического алгоритма для выбора границ частотных диапазонов. На реальных данных электроэнцефалографии показана эффективность предлагаемого метода.

Несмотря на то, что в работе рассматривалась задача распознавания двух типов движений, описываемый метод может быть без каких-либо модификаций использован в задачах с числом классов, большим двух.

Отметим также, что помимо интерфейсов мозг-компьютер, метод может найти применение и в других приложениях. Например, в задачах классификации различных временных рядов, имеющих гармоническую природу, в частности, данных сейсмографии.

Приложение А

Описание тестовых данных

В работе использовался набор тестовых данных *Dataset IIb*, предоставленный Технологическим университетом Граца для проведения соревнования «*BCI Competition IV*» [12]. В состав тестовых данных входят записи электроэнцефалограммы, снятые для девяти испытуемых (B01-B09). Каждый из испытуемых участвовал в пяти сессиях, проводимых в разные дни. В первых двух сессиях обратная связь не использовалась, в остальных трех сессиях на экране монитора отображалась текущая активность мозга.

Во время записи ЭЭГ испытуемым требовалось представлять движения двух типов: левой рукой (класс 1) и правой рукой (класс 2). Каждый испытуемый располагался в мягком кресле напротив экрана компьютера (на расстояние 1 м). В сессиях без предъявления обратной связи в начале пробы ($t = 0, c$) на экране появлялся крест. Спустя 3 секунды ($t = 3, c$) подавался короткий звуковой сигнал, и крест сменялся стрелкой, указывающей влево или вправо, в зависимости от типа воображаемого движения. В течение 4 секунд после предъявления стрелки испытуемый должен был представлять движение требуемого класса. Далее экран становился черным, что говорило об окончании пробы.

В сессиях с обратной связью в начале каждой пробы в центре экрана появлялся смайл серого цвета. После короткого звукового сигнала в момент времени $t = 3, c$ на экране отображался стимул в виде вертикальной линии с левой или с правой стороны экрана, в зависимости от требуемого типа воображаемого движения. Далее в течение 4,5

секунд испытуемому с помощью обратной связи предлагалось сместить смайл в направлении стимула. Если смайл двигался в правильном направлении он изменял цвет на зеленый, в противном случае – на красный. В момент времени $t = 7{,}5$, *с* экран становился черным, что свидетельствовало об окончании пробы.

Запись ЭЭГ производилась с частотой дискретизации 250 Гц по трем биполярным отведениям, образованным электродами C3, Cz, C4 и электродом Fz. Обозначение и расположение электродов соответствовало стандартной системе «10-20%» [2]. В сессиях без обратной связи чувствительность электроэнцефалографа была установлена равной 100 мкВ, в сессиях с обратной связью – равной 50 мкВ.

Дополнительно с помощью трех электродов выполнялась регистрация электроокулограммы (ЭОГ). Однако в данной работе записи ЭОГ не использовались.

В сессиях без обратной связи для каждого испытуемого было получено по 120 проб (60 проб для класса 1 и 60 проб для класса 2), в сессиях с обратной связью – по 160 проб для испытуемого (по 80 проб каждого класса).

При проведении соревнования данные, полученные в двух сессиях без обратной связи и первой сессии с обратной связью, использовались в работе в качестве обучающей выборки. В качестве тестовой выборки использовались записи ЭЭГ, полученные в последних двух сессиях с обратной связью.

Список литературы

1. Dornhege G., Millan J. del R., Hinterberger T., McFarland D.J., Muller K.-R., eds. Toward Brain-Computer Interfacing. A Bradford book. The MIT Press, 2007. 520 p.
2. Зенков Л.Р. Клиническая электроэнцефалография (с элементами эпилептологии). Руководство для врачей. 3-е изд. М.: МЕДпрессинформ, 2004. 368 с.
3. Ang K.K., Chin Z.Y., Zhang H., Guan C. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface // Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN'08). Hong Kong. IEEE Publ., 2008. P. 2391-2398. DOI: 10.1109/IJCNN.2008.4634130
4. Chin Z.Y., Ang K.K., Wang C., Guan C. Multi-class Filter Bank Common Spatial Pattern for Four-Class Motor Imagery BCI // 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC 2009). Minneapolis, Minnesota, USA. IEEE Publ., 2009. P. 571-574. DOI: 10.1109/IEMBS.2009.5332383
5. Thomas K.P., Guan C., Tong Lau C. Adaptive tracking of discriminative frequency components in electroencephalograms for a robust brain–computer interface // Journal of Neural Engineering. 2011. Vol. 8, no. 3. P. 1-15. DOI: 10.1088/1741-2560/8/3/036007
6. Billinger M., Kaiser V., Neuper C., Brunner C. Automatic frequency band selection for BCIs with ERDS difference maps // Proceedings of the Fifth International Brain-Computer Interface Conference. Graz, 2011. P. 44-47.

7. Schomer D.L., da Silva F.H.L., eds. Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields. 6th ed. Lippincott Williams & Wilkins, 2011. 1296 p.
8. Chui C.K. An Introduction to Wavelets. Vol. 1. San Diego: Academic Press, 1992. 265 p.
9. Карпенко А.П. Современные алгоритмы поисковой оптимизации. Алгоритмы, вдохновленные природой: учеб. пособие. М.: Изд-во МГТУ им. Н.Э. Баумана, 2014. 446 с.
10. Chen P.H., Lin C.J., Scholkopf B. A tutorial on ν-support vector machines // Applied Stochastic Models in Business and Industry. 2005. Vol. 21, iss. 2. P. 111-136. DOI:10.1002/asmb.537
11. Сотников П.И. Обзор методов обработки сигнала электроэнцефалограммы в интерфейсах мозг-компьютер // Инженерный вестник. МГТУ им. Н.Э. Баумана. Электрон. журн. 2014. № 10. С. 612-632. Режим доступа: http://engbul.bmstu.ru/doc/739934.html (дата обращения 01.05.2015).
12. Brunner C., Leeb R., Müller-Putz G. BCI Competition 2008 - Graz data set B // BBCI: Berlin Brain-Computer Interface: website. Режим доступа: http://www.bbci.de/competition/iv/ (дата обращения 01.05.2015).
13. Carletta J. Assessing agreement on classification tasks: The kappa statistic // Computational Linguistics. 1996. Vol. 22, no. 2. P. 249-254.

Science & Education of the Bauman MSTU
Electronic journal
ISSN 1994-0408

Science and Education of the Bauman MSTU, 2015, no. 06, pp. 217–234.

DOI: **10.7463/0615.0778091**

Received: 15.05.2015

© Bauman Moscow State Technical Unversity

Selection of Optimal Frequency Bands of the Electroencephalogram Signal in Brain-Computer Interface

P.I. Sotnikov[1,*]

[*]sotnikoffp@gmail.com

[1]Bauman Moscow State Technical University, Moscow, Russia

Keywords: brain-computer interfaces (BCI), electroencephalogram (EEG) analysis, frequency bands selection, genetic algorithm

This article proposes a new method to increase the performance of brain-computer interface (BCI) taking into account the individual characteristics of users. The idea of the method consists in the automatic selection of the most informative frequency bands of the electroencephalogram (EEG) signal. As a measure of information content we use the accuracy of the imagery movement classes' separation. The first part of the article explores differences in sensorimotor rhythms of the EEG signal between users. The second part provides a mathematical formulation of the optimal frequency bands selection problem, which is considered as a one-criterion optimization task. Boundaries of the frequency bands are considered as the variable parameters while the assessment of the classification accuracy acts as an objective function. In the following sections we propose to find a solution of the optimization task using a genetic algorithm. In the last section we compare the efficiency of the described method with other ones, including the algorithm based on the estimation of the EEG signal energy in the classical frequency bands. As a test data we use EEG recordings submitted to BCI Competition IV. In conclusion the main results and future lines of research are discussed.

References

1. Dornhege G., Millan J. del R., Hinterberger T., McFarland D.J., Muller K.-R., eds. *Toward Brain-Computer Interfacing. A Bradford book*. The MIT Press, 2007. 520 p.
2. Zenkov L.R. *Klinicheskaya elektroentsefalografiya (s elementami epileptologii). Rukovodstvo dlya vrachei* [Clinical electroencephalography (with elements epileptology). Guide for physicians]. Moscow, MEDpressinform Publ., 2004. 368 p. (in Russian).
3. Ang K.K., Chin Z.Y., Zhang H., Guan C. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. *Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN'08)*. Hong Kong. IEEE Publ., 2008, pp. 2391-2398. DOI: 10.1109/IJCNN.2008.4634130

4. Chin Z.Y., Ang K.K., Wang C., Guan C. Multi-class Filter Bank Common Spatial Pattern for Four-Class Motor Imagery BCI. *31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC 2009)*, Minneapolis, Minnesota, USA. IEEE Publ., 2009, pp. 571-574. DOI: 10.1109/IEMBS.2009.5332383
5. Thomas K.P., Guan C., Tong Lau C. Adaptive tracking of discriminative frequency components in electroencephalograms for a robust brain–computer interface. *Journal of Neural Engineering*, 2011, vol. 8, no. 3, pp. 1-15. DOI: 10.1088/1741-2560/8/3/036007
6. Billinger M., Kaiser V., Neuper C., Brunner C. Automatic frequency band selection for BCIs with ERDS difference maps. *Proceedings of the Fifth International Brain-Computer Interface Conference*, Graz, 2011, pp. 44-47.
7. Schomer D.L., da Silva F.H.L., eds. *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. 6th ed. Lippincott Williams & Wilkins, 2011. 1296 p.
8. Chui C.K. *An Introduction to Wavelets. Vol. 1*. San Diego, Academic Press, 1992. 265 p.
9. Karpenko A.P. *Sovremennye algoritmy poiskovoi optimizatsii. Algoritmy, vdokhnovlennye prirodoi* [Modern algorithms of search engine optimization. Algorithms inspired by nature]. Moscow, Bauman MSTU Publ., 2014. 446 p. (in Russian).
10. Chen P.H., Lin C.J., Scholkopf B. A tutorial on ν-support vector machines. *Applied Stochastic Models in Business and Industry*, 2005, vol. 21, iss. 2, pp. 111-136. DOI:10.1002/asmb.537
11. Sotnikov P.I. Review of electroencephalogram signal processing techiques in brain-computer interfaces. *Inzhenernyi vestnik MGTU im. N.E. Baumana = Engineering Herald of the Bauman MSTU*, 2014, no. 10, pp. 612-632. Available at: http://engbul.bmstu.ru/doc/739934.html , accessed 01.05.2015. (in Russian).
12. Brunner C., Leeb R., Müller-Putz G. *BCI Competition 2008 - Graz data set B*. BBCI: Berlin Brain-Computer Interface: website. Available at: http://www.bbci.de/competition/iv/ , accessed 01.05.2015.
13. Carletta J. Assessing agreement on classification tasks: The kappa statistic. *Computational Linguistics*, 1996, vol. 22, no. 2, pp. 249-254.