

УДК 004.358

А.П. Гусев^{1,2}, А.М. Андреев²

¹ПАО «ИНЭУМ им. И.С. Брука»

²МГТУ им. Н.Э. Баумана

A. Gusev, A. Andreev

АДАПТИВНАЯ ФИЛЬТРАЦИЯ И ВЫДЕЛЕНИЕ ПРИЗНАКОВ ПОТОКОВЫХ СИГНАЛОВ ЭЭГ

ADAPTIVE FILTRATION AND PATTERN RECOGNITION IN EEG DATA FLOW

Значительная часть алгоритмов обработки биологических сигналов, содержащих адаптивную фильтрацию электроэнцефалограммы, не дает желаемых результатов или фильтрует полезные данные. Одна из причин кроется в недостаточном понимании составляющих сигнала, другая – в недостатке инструментов для адаптации цифровых фильтров. В статье предлагается механизм для обработки артефактов и выделения интегрированных признаков, дающих возможность автоматизированного планирования функции преобразования данных. Адаптивный алгоритм опирается на усеченное вейвлет-преобразование, сегментирование блоков с активностью интегрированных признаков, корреляционную и пороговую диагностику данных для подбора фильтров. Результатом разработанной методики является удобное представление информации о типе сигнала (количестве артефактов, активности головного мозга, типе сенсоров) и адаптивная фильтрация, с расширяющимся набором сложных модулей, улучшающая показатели конечной классификации в устройстве нейроинтерфейса.

The main part of biological data processing algorithms, containing adaptive filtration of electroencephalography, does not have a better results or filtration of useful data. The one part of problem is about misunderstandings of signal semantic components; the other is about use ability of adaptive filtration tools. This article suggests mechanism of filtration of artefacts and integrative patterns, giving the ability to construct adapted filter. The algorithm based on wavelet transformation, active block segmentation, correlative and threshold diagnostic for parametrization of filter. The results of developed methodic gives useful data representation about signal type (artifacts, cerebral activity, type of sensors) and effective filtration with scaled set of modules, giving a better classification in neurointerface device.

Ключевые слова: биологические сигналы, активность мозга, адаптивная

фильтрация, ЭЭГ, нейроинтерфейс.

Keywords: biological signals, cerebral activity, adaptive filtration, EEG, neurointerface.

Введение

Цель данной работы – показать важность предварительной фильтрации биологического сигнала и сформировать концепцию качественного выделения признаков сигнала, интегрированных в одном и том же частотном сегменте спектральной функции. Часто, используя адаптивные методы фильтрации, обработанный сигнал утрачивает большое количество интегрированных признаков или теряется при появлении стандартных биологических фоновых сигналов (таких как альфа- и мю-ритмы). Это приводит к дальнейшим потерям информативности сигнала и снижению эффективности целевой обработки (в качестве целевой обработки может выступать классификатор, регрессор или анализатор мощности). Для улучшения показателей необходима методика, которая дает возможность объединять выделение нескольких типов признаков, имеет модульную структуру и позволяет очищать сигнал от уже распознанных признаков.

Так как объект фильтрации (имеются в виду альфа-, бета-, гамма-, мю-ритмы и длиннотентные вызванные потенциалы) имеет вполне конкретную и хорошо описанную на уровне базовых представлений модель, необходимо выделить критерии сигнала, признаки их интеграции и определить методы для получения лучших результатов анализа. Реализация поставленных задач позволит существенно улучшить качество работы интерфейсов мозг-компьютер (ИМК).

По мнению аналитиков ABI Research [1], статистические данные и всплеск интереса мирового научного сообщества к ИМК сигнализируют о скором и достаточно активном росте рынка. Согласно аналитическим данным, в 2016 году ИМК-совместимое оборудование медицинского и бытового назначения принесет компаниям совокупно порядка 15 миллионов долларов США. Лидерами на данном направлении считаются компании из Великобритании и Японии.

Новое поколение интерфейсов на основе анализа электроэнцефалограммы также обещает полнее реализовывать функционал для любителей киберспорта и компьютерных игр [2].

1. Обзор существующих методик

Проанализируем различные методики работы с биологическими сигналами и общемировые практики [3]. Для удобства представления сведем данные в таблицу 1.

Таблица 1. Обзор перспективных методик предобработки сигнала

№ п/п	Авторы	Техника извлечения сигнала	Используемая физиология	Классификационный параметр	Результат
1	Zhou [4]	Биспектральный анализ	Воображение движения	Правая и левая руки	Незначительное улучшение показателей
2	Hubert Cecotti and Axel Graser [5]	Анализ при помощи обученного перцептрона	Вызванные потенциалы	Распознавание символа на клавиатуре	Незначительное улучшение показателей
3	Coyl [6]	SOFNN	Воображение движения	Левая и правая руки	Менее 90% при 10 бит/мин
4	Rakendu Rao [7]	Анализ независимых компонент	Ментальные операции	Умножение, воображение символа, счет.	Уменьшена ошибка классификации
5	Baretto [8]	Периодограмма Уэлча	Воображение движения	Левая и правая руки	Менее 73%
6	Yong [9]	Стационарное вейвлет-преобразование и механизм адаптивной границы	Мю-, бета- и альфа-ритмы	Мощность в спектральном представлении	Уменьшение шума сигнала и увеличение процента классификации

Анализируя полученную таблицу, можно сказать, что методы 3, 5 и 6 дают лучшие результаты обработки сигнала. Однако методы 3 и 5 вычисляются *a posteriori* [8], т.е. применяются только на уже записанном сигнале и не дают гарантии, что преобразованный из нестационарного сигнал станет стационарным [10]. Это делает их неприменимыми в качестве предобработки сигнала в устройстве реального времени.

Рассмотренное в методе 6 вейвлет-преобразование [9] представляет собой масштабируемое окно преобразования Фурье со следующим определением:

$$W(a, b; X, \psi) = |a|^{-1/2} \int_{-\infty}^{\infty} X(t) \psi^* \left(\frac{t-b}{a} \right) dt,$$

где $\psi^*(\cdot)$ – базовая вейвлет-функция, a – фактор дилатации, b – транслятор. Причем, в общем смысле $\psi^*(\cdot)$ не обладает свойством ортогональности; ее можно привести к ортогональности, выбрав дискретный набор значений параметра a . Приведем формулу к дискретному виду, в котором она и была использована, введя дискретизацию по фактору дилатации и транслятору:

$$DW(n, m; X, \psi) = W(c_0^n, m \cdot T \cdot c_0^n; X, \psi)$$

$$DW(n, m; X, \psi) = \frac{1}{\sqrt{c_0^n}} \sum_{k=0}^{K-1} X[t] \psi^* \left[\left(\frac{t}{c_0^n} - m \right) T \right],$$

где c_0 – базовый масштабируемый коэффициент, T – базовый коэффициент трансляции.

Такое дискретное вейвлет-преобразование потеряет сигналы, имеющие растяжение, не соответствующее набору частот, а нижняя часть спектра сигнала будет иметь низкое разрешение. Например, при базовом коэффициенте, равном 2, частоты на интересующем нас промежутке будут принимать значения 1, 2, 4, 8, 16, ... Целевые же частоты находятся в значениях 3, 7, 10, 14 и имеют распределение, приближенное к равномерному. Это делает полное дискретное вейвлет-преобразование не вполне подходящим для использования в обработке биологических сигналов.

Для улучшения параметров выделения признаков и фильтрации сигнала предлагается построить фильтр с адаптивной структурой на основе полосовых фильтров интересующих нас частот.

2. Структура системы

При реализации алгоритмов фильтрации на конечном устройстве в расчет принимаются три основных параметра: эффективность, ресурсная стоимость и постоянство результата. Если поставить задачу более конкретно, то алгоритм должен выполняться на устройстве контроллера с производительностью не более 210 MIPS, быть устойчивым к артефактам и существенно улучшать классификацию команд.

Сам целевой сигнал электроэнцефалограммы при этом является нестационарным, за

исключением интегрированной реакции на предъявляемый стимул (вызванного потенциала), которая является стационарной и периодической (частота предъявления стимулов порядка 7 Гц). Выделение целевого сигнала также осложнено наличием двух типов шумовых сигналов: артефактов (окулярных и двигательных) и биологических сигналов отличного функционала, не анализируемых нами в классификаторе.

Соотнесем такие сигналы, как функциональные ритмы мозга, с их частотой и условиями возникновения в таблице 2 [11]. Примеры функциональных ритмов мозга во временной области приведены на рисунке 1 [11].

Таблица 2. Функциональные ритмы мозга

Название ритма	Частота, Гц	Локализация	Условия, в которых наблюдаются ритмы
Дельта	0-4	Фронтально у взрослых, постериально у детей	Глубокий сон. Выполнение заданий на внимание
Тета	4-7	Гиппокамп, кора	Сонливость или пробуждение у старших детей или взрослых. Простой (бездействие). Угнетение отклика на стимулы (был найден в ситуациях, когда субъект активно пытается сдержать какое-то действие или реакцию)
Альфа	8-12	Постериальные участки головы, с обеих сторон, но с большей амплитудой на недоминантной стороне. Центральные локации (с3-с4) во время отдыха	В расслабленном состоянии. С закрытыми глазами. Участие в контроле сдерживания, вероятно с целью планирования тормозной активности в различных участках мозга
Бета	13-30	Обе стороны, больше всего фронтально; волны малой амплитуды	Активное/внимательное состояние. Активная концентрация, занятость или тревожное мышление
Гамма	30-100+	Соматосенсорная кора	Межмодальная обработка сенсорной информации (восприятие сочетает два различных ощущения , например, звук и визуальную картинку). Во время работы кратковременной памяти (распознавание объектов, звуков, тактильных ощущений)
Мю	8-13	Соматосенсорная и моторная кора	Моторные нейроны во время бездействия

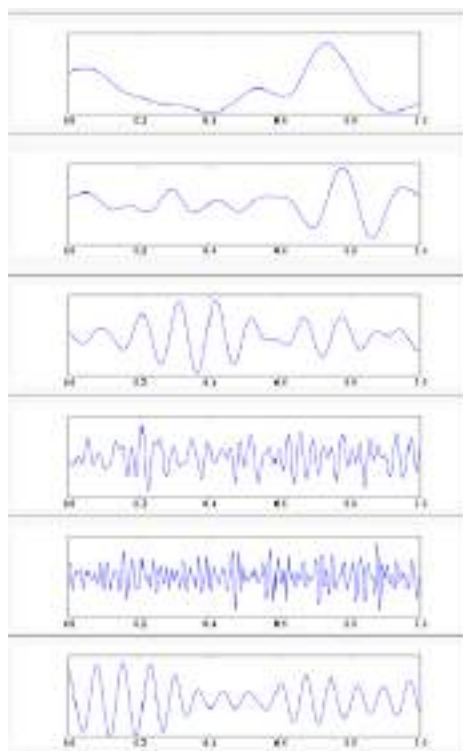



Рисунок 1. Графики фоновых ритмов, сверху вниз: дельта-, тета-, альфа-, бета-, гамма- и мю-ритмы

Исходя из таблицы 2, можно свести все типы ментальных ритмов к пяти частотным группам. Для их фильтрации и/или обнаружения сигналов такого типа мы рассчитали пять оконных полосовых фильтров с конечной импульсной характеристикой, шириной в 5 Гц и подавлением в 20 дБ. Расчет коэффициентов фильтров проводился при помощи инструментария среды MATLAB, однако он прост и в реализации собственным программным кодом. Порядок фильтра определяется размером буфера данных конечного разрабатываемого устройства (64 отсчета в нашем случае).

1. Полосовой фильтр с диапазоном частот 0,1–5 Гц (рисунок 2), 64 порядка. Предназначен для выделения двигательных артефактов, морганий глаз, дельта-волн, отвечающих за внимание при выполнении ментальной задачи.






Рисунок 5. Полосовой фильтр с диапазоном частот 11–17 Гц: а – магнитудно-частотная характеристика; б – частотная характеристика задержки (в семплах); в – импульсная характеристика

5. Полосовой фильтр с диапазоном частот 15–80 Гц (рис. 6), 64 порядка. Предназначен для выделения бета-ритмов (2-го порядка) и высокочастотных наводок электроники.




Рисунок 6. Полосовой фильтр с диапазоном частот 15–80 Гц: а – магнитудно-частотная характеристика; б – частотная характеристика задержки (в семплах); в – импульсная характеристика

Имея оконные фильтры, представляющие собой более эффективную форму выделения признаков ментальной активности, чем дискретное вейвлет-преобразование, получаем разложение сигнала на его функциональный спектр на рисунке 7.




Рисунок 7. Сигнал ЭЭГ и его компонентно-функциональное разложение во временной области. На третьей секунде эксперимента пользователя попросили закрыть глаза

(окулярный артефакт и последующий альфа-ритм)

Полученные составляющие сигнала подвергаются пороговой обработке по следующей формуле [12]:

$$ADThr(f_i(t)) = \begin{cases} f_i(t), \text{ if } \frac{\sum_{k=1}^N |f_i(t-k)|}{N} > (\max f_m - \min f_m) \times p \\ 0, \text{ if } \frac{\sum_{k=1}^N |f_i(t-k)|}{N} \leq (\max f_m - \min f_m) \times p \end{cases}$$

где f_m – исходный сигнал, f_i – функциональная составляющая, p – порог, подобранный эмпирически (в нашем случае 0,2).

Наложение такого порога на каждую компоненту необходимо для удаления дребезга краевых эффектов при фильтрации. Компоненты, преодолевшие установленный порог, вычитаются из исходного сигнала для получения фильтрованных данных.

Используя рассчитанные блоки полосовых фильтров и пороговое правило, построим функциональную модель системы съема и предварительной обработки данных ЭЭГ (рисунок 8).

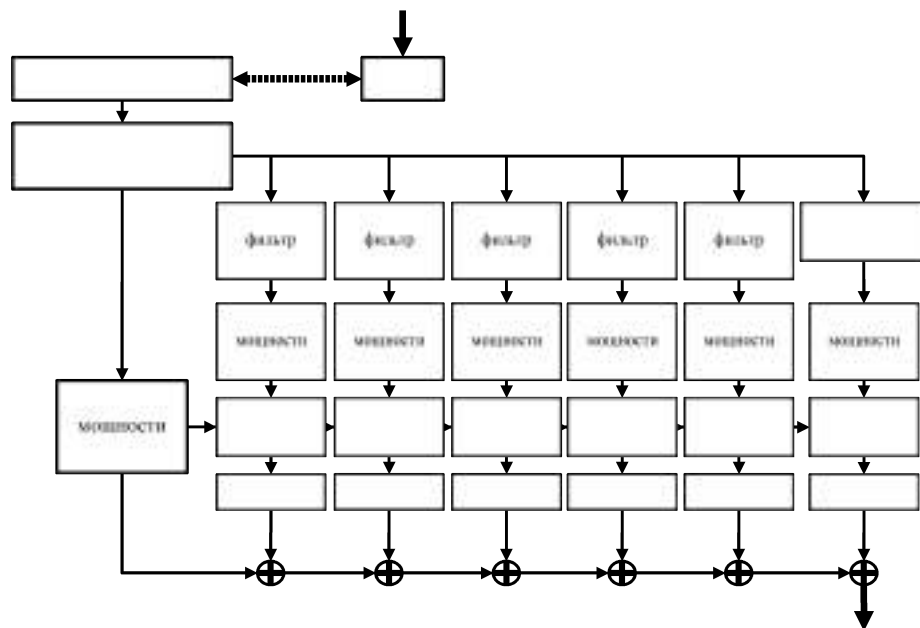


Рисунок 8. Функциональная модель системы съема и предварительной обработки данных ЭЭГ

3. Экспериментальная проверка алгоритма

Для проверки разработанной системы использовались уже записанные данные проведенных экспериментов «сVER» и «р300». Фильтрация проводилась без предварительной информации о типе эксперимента.

Эксперимент «р300» состоял из 40 заданий. Задание выполнялось по следующей схеме. В одной из четырех позиций предъявителя загорался зеленый квадрат в центре (на 128 мс), обозначающий позицию, в которой испытуемому необходимо было отсчитать количество предъявлений голубой рамки. Спустя 128 мс после индикации зеленого сигнала начиналась стимуляция. Длительность предъявления рамки – 128 мс, паузы между ними – 128 мс. Позиции, в которых предъявлялась рамка, выбирались в случайном порядке, причем в одной и той же позиции рамка не могла предъявляться два раза подряд. После того как испытуемый отсчитывал все загорания рамки в одной и той же позиции (шесть стимулов), задание повторялось сначала. Диаграмма предъявления стимулов изображена на рисунке 9.




Рисунок 9. Диаграмма предъявления стимулов, протокол стимуляции «р300»

Для эксперимента «сVER» использовался другой протокол. В одной из четырех позиций предъявителя загорался зеленый квадрат в центре (на 512 мс), обозначающий позицию, в которую испытуемому необходимо было перенести внимание. Через 512 мс после этого начиналась стимуляция, как показано на рисунке 10. Частота стимуляции –

31 Гц (31 такт/с). Стимуляция происходила во всех четырех позициях предъявителя, но испытуемый при этом концентрировался на позиции, заданной заранее.




Рисунок 10. Диаграмма предъявления стимулов, протокол стимуляции «сVEP»

Эксперименты были записаны на устройстве нейроинтерфейса, разработанного ПАО «ИНЭУМ им. И.С. Брука», с разными испытуемыми в различном психофизическом состоянии. Также варьировался тип контакта (использовался сухой контакт и с проводящим гелем).

На рисунке 11 представлены данные о качестве классификации целевых команд в контрольной выборке экспериментов в процентах. Как видно, качество распознавания повысилось в среднем на 10-20% и не зависело от типа эксперимента.




Рисунок 11. Контрольная выборка экспериментов и качество классификации их признаков

Заключение

В заключение отметим, что реализация такого алгоритма обработки позволила решить следующие задачи:

- удалить двигательные и окулографические артефакты;
- убрать десинхронизированные сигналы фоновых ритмов;
- увеличить процент верно классифицированных команд.

Помимо улучшенной фильтрации данных также получена локализация активности определенных биологических ритмов и артефактов, что позволяет использовать их для задач управления и диагностики.

Дальнейшим развитием работы может являться добавление к адаптивной фильтрации методик корреляционного анализа между парами электродов или введение некоей общей корреляционной функции для всех наборов электродов.

ЛИТЕРАТУРА

1. <http://www.businesswire.com/news/home/20150727005820/en/Brain-to-Machine-Interface-Market-Top-US200-Million-2020#.Vbhva1IuPPx>. [Электронный ресурс] (дата обращения 06.01.2016).
2. <https://www.abiresearch.com/> [Электронный ресурс] (дата обращения 07.01.2016).
3. R. Pamavathi, V. Ranganathan. A review on EEG based brain computer interface systems. // International Journal of Emerging Technology and Advanced Engineering. 2014. P. 683.
4. Zhou Shang-Ming. Classifying mental tasks based on features of higher-order statistics from EEG signals in brain-computer interface / Shang-Ming Zhou, John Q. Gan, Francisco Sepu // Information Sciences, 2008, pp. 1629-1640.
5. Hubert Cecotti and Axel Graser. Neural network pruning for feature selection Application to a P300 Brain-Computer Interface // European Symposium on Artificial Neural Networks. Advances in Computational Intelligence and Learning. Bruges (Belgium), 2008,

pp. 473-478.

6. Damien Coyle, Girijesh Prasad and Thomas M. McGinnity. Extracting Features for a Brain-Computer Interface by Self-Organising Fuzzy Neural Network-based Time Series Prediction // Proceedings of the 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (San Francisco, CA), 2004, pp. 4371-4374.

7. Rakendu Rao and Reza Derakhshani. A Comparison of EEG Preprocessing Methods using Time Delay Neural Networks // Proceedings of the 2 International IEEE EMBS Conference on Neural Engineering Arlington, Virginia, March 16-19, 2005.

8. Guilherme A. Barreto, Rewbenio A. Frota and Fatima N.S. de Medeiros. The Classification Of Mental Tasks: A Performance Comparison Of Neural And Statistical Approaches // In Proceedings of the IEEE Workshop on Machine Learning for Signal Processing, 2004.

9. X. Yong, M. Fatourechi, R.K. Ward, and G.E. Birch. Automatic artefact removal in a self-paced hybrid brain-computer interface system // Journal of Neuro Engineering and Rehabilitation, vol. 9, article 50, 2012.

10. Huang N.E., Shen Z., Long S.R., Wu M.C., Shih H.H., Zheng Q., Yen N.-C., Tung C.C., and Liu H.H. [The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis](#) // Proc. R. Soc. Lond. A. 1998. T. 454. P. 903-995.

11. Buzsáki György. Rhythms of the Brain. – Oxford University Press, 2006.

12. Кривоногов Л.Ю., Папшев Д.В. Повышение эффективности подавления высокочастотных помех в электрокардиосигналах // Измерение. Мониторинг. Управление. Контроль. – 2014. – № 2 (8). – С. 17–24.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Гусев Арсентий Петрович, аспирант МГТУ им. Н.Э. Баумана, инженер, ПАО «ИНЭУМ им. И.С. Брука», 119334, Москва, ул. Вавилова, д. 24, (495)455-84-93, gusev_a@ineum.ru.

Андреев Арк Михайлович, к.т.н., доцент, Московский государственный технический

университет им. Н.Э. Баумана, 105005, Москва, ул. 2-я Бауманская, д. 5, стр. 1, (499)263-62-84, arkandreev@gmail.com