



Московский государственный университет имени М. В. Ломоносова

Факультет вычислительной математики и кибернетики

Кафедра математических методов прогнозирования

ЗИННУРОВА Эльвира Альбертовна

**Управление динамическим объектом
с использованием нейрокомпьютерного интерфейса**

ДИПЛОМНАЯ РАБОТА

Научный руководитель:

к.ф.-м.н., доцент

С.И. Гуров

Москва, 2015

Содержание

| | | |
|----------|--|-----------|
| 1 | Введение | 3 |
| 2 | Постановка задачи | 5 |
| 3 | Нейрокомпьютерные интерфейсы | 6 |
| 3.1 | Используемое оборудование | 6 |
| 3.2 | Типы нейрофизиологических сигналов | 8 |
| 3.3 | Нейрокомпьютерные интерфейсы на основе волн P300 | 13 |
| 4 | Методы обработки данных ЭЭГ | 16 |
| 4.1 | Предобработка | 16 |
| 4.2 | Построение признакового пространства | 18 |
| 4.3 | Классификация | 24 |
| 4.4 | Критерий качества | 27 |
| 5 | Проведение эксперимента | 29 |
| 5.1 | Парадигма эксперимента | 29 |
| 5.2 | Схема эксперимента | 31 |
| 6 | Предлагаемый подход | 34 |
| 6.1 | Предобработка | 34 |
| 6.2 | Отбор признаков | 35 |
| 6.3 | Классификация | 36 |
| 6.4 | Тестирование | 38 |
| 7 | Результаты | 39 |
| 7.1 | Результаты с положением устройства по умолчанию | 39 |
| 7.2 | Результаты с инверсированным положением устройства | 40 |
| 7.3 | Обсуждение и выводы | 40 |
| 8 | Заключение | 43 |
| | Список литературы | 44 |

1 Введение

Нейрокомпьютерный интерфейс (англ. *brain-computer interface, mind-machine interface, brain-machine interface*, интерфейс «мозг-компьютер», зачастую используется сокращение *BCI*) — специальный вид интерфейса, созданный для обмена информацией между мозгом и средствами вычислительной техники. Одной из задач, стоящих перед исследователями, работающими в данной области, является создание устройств, которые позволят людям с утраченными способностями организма полноценно взаимодействовать с окружающим миром.

В последние годы ведётся активная разработка различных практических приложений с использованием интерфейса «мозг-компьютер». Многие исследовательские группы по всему миру занимаются тематикой *BCI*, и в разработке многих направлений тематики имеются заметные успехи, однако до сих пор существует масса сложностей в практическом применении нейрокомпьютерного интерфейса. Управление объектами реального мира может быть использовано в широком спектре областей, в частности, в медицине, развлекательной индустрии и пр.

Тем не менее, на сегодняшний день распознавание воображаемых движений является стандартной задачей, разработаны алгоритмы, практически безошибочно классифицирующие ментальные задания, однако построенные системы *BCI* сложно назвать приспособленными для использования с практической точки зрения.

Основной целью данной работы является разработка нейрокомпьютерного интерфейса для управления динамическим объектом в некотором направлении с использованием общедоступного коммерческого устройства *Emotiv EPOC*. Кроме того, в данной дипломной работе проводится обзор существующих систем *BCI* и распространённых подходов к решению подобного рода задач.

В первой главе даётся формальная постановка решаемой задачи.

Далее описано используемое в данной работе оборудование, перечислены типы нейрофизиологических сигналов и объяснены причины, благодаря которым становится возможным решение поставленной задачи, а также обозначены имеющиеся на сегодняшний день проблемы при решении подобного рода задач.

Затем перечислены и описаны алгоритмы, наиболее часто применяемые при решении задач в области нейрокомпьютерных интерфейсов, а также представлены наиболее распространённые методы сравнения систем *BCI*.

После этого описывается процесс и методика получения данных в течение проводимых экспериментов, а также предлагаемый подход к распознаванию регистрируемых данных.

Далее представлены полученные результаты и проведено сравнение полученной точности с аналогичными исследованиями в данной области, а также приведены основные выводы, сделанные по результатам имевших место исследований.

2 Постановка задачи

Целью данной работы является разработка нейрокомпьютерного интерфейса для управления динамическим объектом в некотором направлении с использованием общедоступного коммерческого устройства *Emotiv EPOC*, предназначенного для регистрации активности головного мозга при помощи зафиксированных сенсоров. Данное устройство подробно описано в разделе 3.1.

Пусть имеется N_e сенсоров, в моменты времени $1, 2, \dots, t, \dots$ i -ый сенсор фиксирует значения $x^i(t)$, $i = \overline{1, N_e}$. Требуется определить класс регистрируемого в произвольный момент времени t сигнала, в частности, в данной работе в качестве классов выступают возможные направления движения курсора. Обычно полагают, что многомерный сигнал разбит на отрезки фиксированной длины T , на протяжении каждого из которых класс сигнала остаётся неизменным. Везде далее будем придерживаться данного предположения.

Дадим формальную математическую постановку задачи.

Имеется пространство объектов $\mathcal{X} \subset \mathbb{R}^{N_e \times T}$, каждый из которых представляет собой сигнал, зафиксированный при помощи N_e сенсоров, также называемых *электродами*, в течение периода времени T , и конечное множество имён классов \mathcal{Y} . Существует целевая зависимость $y^* : \mathcal{X} \rightarrow \mathcal{Y}$, значения которой известны только на объектах обучающей выборки $X^L = \{(x^i, y^i)\}_{i=1}^L$, $x^i \in \mathcal{X} \subset \mathbb{R}^{N_e \times T}$, $y^i = y^*(x^i) \in \mathcal{Y}$, L – количество объектов обучающей выборки. Требуется построить алгоритм классификации $a : \mathcal{X} \rightarrow \mathcal{Y}$, аппроксимирующий целевую зависимость $y^*(x)$ на всем множестве \mathcal{X} в соответствии с некоторым введённым функционалом качества.

3 Нейрокомпьютерные интерфейсы

3.1 Используемое оборудование

Основной целью исследований в области нейрокомпьютерных интерфейсов является разработка систем, позволяющих обездвиженным пользователям обмениваться информацией и взаимодействовать с другими людьми, а также контролировать различные элементы их окружения. Кроме того, подобные системы могут быть использованы для улучшения контроля над сложными многозадачными операциями.

Нейрокомпьютерный интерфейс — средство коммуникации, транслирующее активность головного мозга в действия либо команды, исполняемые электронными устройствами. Фиксация подобного рода активности становится возможной вследствие физико-химических процессов, лежащих в основе обмена веществ в нервной ткани, порождающих колебания потенциалов головного мозга. Несмотря на то что существует множество различных методов фиксации активности головного мозга (электрокортикография¹, электроокулография² и др.), в настоящее время основным способом регистрации сигналов головного мозга является электроэнцефалография.

Электроэнцефалография (ЭЭГ) — раздел электрофизиологии, изучающий закономерности суммарной электрической активности мозга, отводимой с поверхности кожи головы или мозга, а также метод записи таких потенциалов. Получение электроэнцефалограммы осуществляется с помощью специализированных устройств — электроэнцефалографов. Существуют различные устройства для записи ЭЭГ, отличающиеся характеристиками, среди которых:

- характеристики принимающего сигнала (частота, уровень шума в сигнале);
- инвазивность (степень имплантирования электродов в кору головного мозга);
- количество электродов;

¹*Электрокортикография* — метод отведения потенциалов при помощи электродов, накладываемых непосредственно на кору головного мозга. Потенциалы имеют на порядок большую амплитуду по сравнению с ЭЭГ, а также лучшее разрешение.

²*Электроокулография* — исследование глазных мышц и наружного слоя сетчатки благодаря изменениям биопотенциалов во время движения глаза и стимуляции сетчатки, и переводу зарегистрированных изменений в графическое представление.

- покрываемая площадь (среднее количество нейронов, влияющих на сигнал, снимаемый одним электродом).

По инвазивности устройства делятся на *погружные*, *частично-погружные* и *непогружные* в зависимости от расположения электродов (электроды вживлены в мозг/сращены с нервами, находятся на поверхности мозга/рядом с нервами или находятся на поверхности кожи головы соответственно).

Устройства с непогружным интерфейсом делятся на *мокрые* и *сухие* в зависимости от того, необходимо ли смачивание электродов проводящей жидкостью для осуществления контакта.

По типу электродов устройства делятся на *пассивные* и *активные* в зависимости от того, производится ли после снятия электродом сигнала его первичная обработка.

В настоящей работе для записи электроэнцефалограммы использовалось устройство *Emotiv EPOC*. Это устройство было разработано австралийской компанией *Emotiv Systems*, основанной в 2003 году. Данная компания входит в число трёх основных участников рынка потребительских устройств *BCI* наряду с компаниями *NeuroSky* и *OCZ*, однако *Emotiv EPOC* имеет значительно большее число электродов, чем устройства компаний-конкурентов, и незначительно более высокую стоимость.

Общий вид устройства изображён на рис. 1, устройство обладает следующими характеристиками:

- число сенсоров — 14;
- тип сенсоров — пассивные, мокрые;
- частота дискретизации — 128 Гц;
- способ связи — беспроводная радиосвязь;
- гироскопы — 2 шт.;
- инвазивность — непогружной.

Расположение сенсоров устройства в соответствии с системой размещения электродов «10–20%»³ изображено на рис. 2.

³Система «10–20%» — стандартная система размещения электродов на поверхности головы, рекомендованная Международной федерацией электроэнцефалографии и клинической нейрофизиологии. Подробное описание данной системы может быть найдено в [10].



Рис. 1. *Emotiv EPOC*— устройство, используемое для записи данных ЭЭГ.

Устройство *Emotiv EPOC* было использовано в силу своей простоты и доступности. Также достоинствами данного устройства являются портативность и небольшие размеры. В то же время оно обладает и рядом недостатков, среди которых низкая точность снимаемого сигнала и ненадёжная фиксация устройства на голове человека. В рамках настоящей работы будет предпринята попытка купировать недостатки устройства применяемыми методами обработки и классификации сигналов.

3.2 Типы нейрофизиологических сигналов

Предполагается, что идеализированный нейрокомпьютерный интерфейс будет напрямую транслировать всякое намерение пользователя и подавать управляемому устройству сигнал о выполнении соответствующего действия. Однако установление однозначного соответствия между намерениями пользователя и нейрофизиологиче-

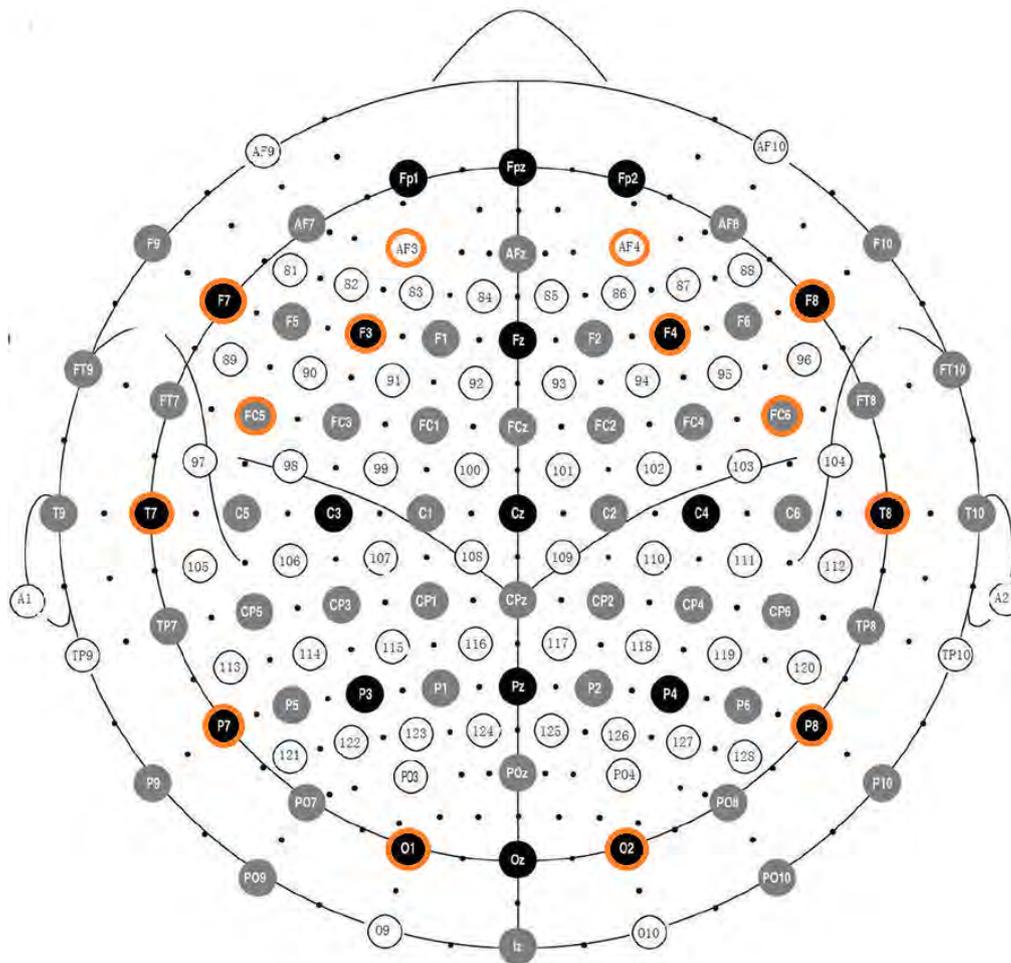


Рис. 2. Расположение электродов на голове человека согласно международной системе размещения электродов «10–20». Электроды устройства *Emotiv EPOC* выделены оранжевым цветом.

скими сигналами является нетривиальной задачей. На сегодняшний день данный факт является одной из основных причин ограниченности свободы действий в существующих системах *BCI*.

Для распознавания различных нейрофизиологических сигналов и возможности сопоставления подобного рода сигналов и подразумеваемых действий необходимо осознанное управление активностью головного мозга. В основном для достижения этой цели используются два подхода. При использовании первого подхода испытуемые подвергаются воздействию набора стимулов нейрокомпьютерного интерфейса, и контроль мозговой активности осуществляется путём концентрации на одном конкретном стимуле. Изменения нейрофизиологических сигналов в силу разли-

чий между стимулами называются *вызванными потенциалами* (англ. *event-related potentials, ERPs*). При использовании второго подхода управление мозговой активностью осуществляется путём выполнения определённого когнитивного (ментального) задания, например, воображаемое представление определённого движения руки может явиться причиной изменения активности в соответствующей части скальпа.

1°. Вызванные потенциалы

Вызванный потенциал — электрическая реакция мозга на внешний раздражитель или на выполнение некоторого ментального задания. Потенциалы данного вида имеют место в течение определённого промежутка времени после воздействия стимула.

Волны P300. Волна P300 — положительное отклонение сигнала ЭЭГ, имеющее место приблизительно через 300 мс после воздействия стимула с малой вероятностью появления, описывающего некоторое действие. Для порождения подобного рода волн испытуемому требуется пронаблюдать последовательность двух типов стимулов. Первый тип стимулов (т.н. *целевые* стимулы) имеет малую вероятность появления в последовательности стимулов, в отличие от другого типа стимулов (т.н. *нецелевые* стимулы). Таким образом, в момент предъявления целевого стимула может быть зафиксирована мозговая активность, содержащая волны P300. Данное явление проиллюстрировано на рис. 3 для данных одного из сенсоров. Данный принцип был применен в системе *BCI*, разработанной в исследовании [1]. В данном исследовании было описано устройство для набора текста. На экране изображалась таблица доступных для набора символов, строки и столбцы которой выделялись в случайном порядке, в качестве целевого стимула выступало выделение столбца/строки с желаемым на данный момент символом, в качестве нецелевых стимулов — выделение остальных столбцов/строк.

Визуальные вызванные потенциалы. Визуальные вызванные потенциалы (англ. *Steady-State Visual Evoked Potentials, SSVEPs*) — осцилляции, имеющие место в данных, полученных при помощи сенсоров, расположенных на затылке. Данные изменения могут быть результатом наблюдения однородного процесса, повторяю-

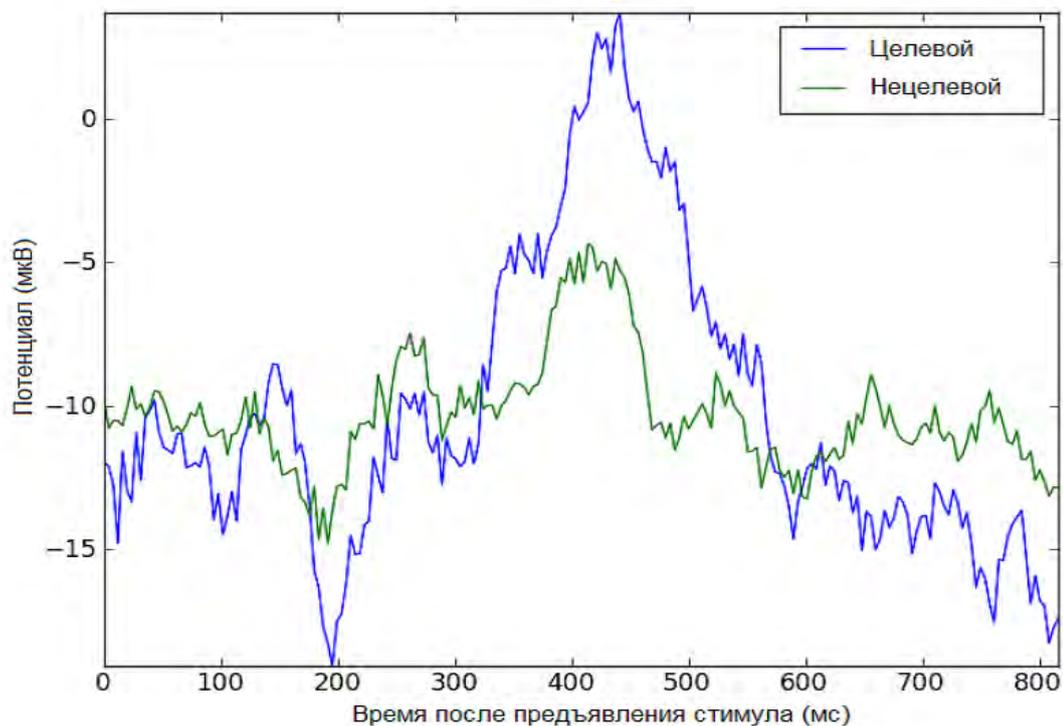


Рис. 3. Данные сенсора O1, зарегистрированные при предъявлении целевого и нецелевого стимулов.

щегося с малой частотой. Подобного рода стимуляция порождает колебания той же частоты в регистрируемых сигналах головного мозга. В исследованиях по тематике нейрокомпьютерных интерфейсов потенциалы этого типа используются при одновременной демонстрации стимулов с разной частотой. Таким образом, пользователь путём концентрации на конкретном стимуле имеет возможность выбора действия, соответствующего данному стимулу.

Моторные вызванные потенциалы. Моторные вызванные потенциалы (англ. *motor-related potentials, MRPs*) — продолжительные отрицательные потенциалы, связанные с ожиданием или ментальным представлением выполняемого движения или действия, имеют место в сенсомоторной части скальпа в начале выполнения движения или в процессе ментального представления движения.

2°. Частотная мозговая активность

В электроэнцефалограмме здорового человека выделяют несколько характерных составляющих электрических колебаний, называемых *ритмами*, различающихся частотным диапазоном, а также амплитудой, формой волны и другими характеристиками. Считается, что каждый ритм соответствует некоторому определённому состоянию мозга и связан с определёнными церебральными механизмами, а потому выделение ритмов, представляющих интерес, исходя из априорных знаний, может быть использовано для декодирования намерений пользователя.

| Ритм | Частота (Гц) |
|----------------|--------------|
| δ -ритм | 1-4 |
| θ -ритм | 4-7 |
| α -ритм | 7-13 |
| β -ритм | 13-30 |
| γ -ритм | 30+ |

Таблица 1. Частотные полосы наиболее изученных ритмов ЭЭГ.

Сенсомоторные ритмы. Колебания μ -ритма могут быть обнаружены в сенсомоторной части скальпа, когда пользователь находится в состоянии покоя. Если же выполняется некоторое фиксированное движение или ментальное представление данного движения, амплитуда колебаний уменьшается. Кроме того, подобные действия также порождают изменения в амплитуде β -ритма. Изменения данных ритмов отражаются на части скальпа, отвечающей перемещаемой части тела, в связи с этим представляемые и выполняемые движения различных частей тела могут быть отличимы друг от друга.

Имеющие место изменения мозговой активности для пользователей с небольшим опытом использования нейрокомпьютерных интерфейсов обычно оказываются недостаточно весомыми для адекватного функционирования распознающих алгоритмов. Кроме того, используемое в данном исследовании устройство не покрывает часть

скальпа, отвечающую за генерацию волн, связанных с подобного рода событиями. В связи с этим в дальнейшем данный подход не будет рассматриваться.

Прочая активность. В качестве триггеров возникновения колебаний потенциалов могут быть использованы когнитивные задания, отличные от представления движений, например, вычисления, слуховые представления, представление движения трёхмерного объекта в пространстве и др.

3.3 Нейрокомпьютерные интерфейсы на основе волн P300

1°. Вызванные потенциалы и волны P300

Волны P300 были впервые отмечены в исследовании [2] в 1965 году. С тех пор имело место множество исследований по изучению природы этих колебаний путём изменения различных характеристик проводимых экспериментов, таких как способ демонстрации стимула, пол, возраст испытуемых, наличие заболеваний и пр.

Существуют исследования, описывающие подходы к управлению динамическим объектом при помощи моторных и визуальных вызванных потенциалов, однако в рамках данной работы в качестве объектов для принятия решения будут выступать волны P300, поскольку используемое оборудование не покрывает участок скальпа, отвечающий за моторные вызванные потенциалы, а визуальные вызванные потенциалы были сочтены не соответствующими поставленной задаче с практической точки зрения.

Различные парадигмы могут быть использованы для выявления волн P300. В качестве стимулов могут быть использованы слуховые, визуальные, тактильные, обонятельные, вкусовые стимулы. Тем не менее, чаще всего используются визуальные и слуховые стимулы, а также их сочетания, поскольку данные типы являются лучшим выбором с практической точки зрения. В основном в большинстве исследований применяются две парадигмы проведения экспериментов: оригинальная (англ. *oddball paradigm*) и трёхстимульная (англ. *three-stimulus paradigm*).

Оригинальная парадигма подразумевает использование двух типов стимулов (целевых и нецелевых), демонстрируемых в произвольном порядке, причём демон-

страция целевого стимула является гораздо более редким событием по сравнению с демонстрацией нецелевого стимула. Испытуемому же необходимо концентрироваться исключительно на целевом стимуле и игнорировать появление нецелевых стимулов.

Трёхстимульная парадигма является модификацией оригинальной парадигмы. В данном случае помимо описанных типов стимулов также присутствуют т.н. *отвлекающие* стимулы, редко появляющиеся в последовательности целевых и нецелевых стимулов. Испытуемые не информируются о наличии подобного рода стимулов в процессе инструктажа.

При использовании описанных парадигм наблюдаются различные типы волн P300. Применение оригинальной парадигмы позволяет обнаружить т.н. волны P3b, имеющие место приблизительно в течение 300-500 мс после воздействия целевого стимула при концентрации на таковом. При использовании же трёхстимульной парадигмы целевой стимул также порождает волны P3b, при этом отвлекающий стимул порождает другой тип волны P300, называемый волной P3a, имеющей место приблизительно в течение 200–400 мс после воздействия стимула. Характер возникновения волн каждого из описанных типов в процессе проведения эксперимента с использованием различных парадигм изображен на рис. 4.

2°. Влияние различных факторов на волны P300

Кроме влияния различных экспериментальных парадигм, упомянутых выше, волны P300 также подвержены влиянию многих других факторов [14] [15] [16], перечисленных ниже.

Вероятность появления целевого стимула. Амплитуда волны P3b обратно пропорциональна вероятности появления целевого стимула: редкое появление целевого стимула порождает высокий пик волны, в то время как высокая вероятность появления стимула слабо отражается на сигнале. В основном при проведении экспериментов вероятность появления данного типа стимулов полагается примерно равной 10% для более надёжного выявления волн P300. Кроме того, на амплитуду волны P3b также влияет локальная вероятность появления целевого стимула.

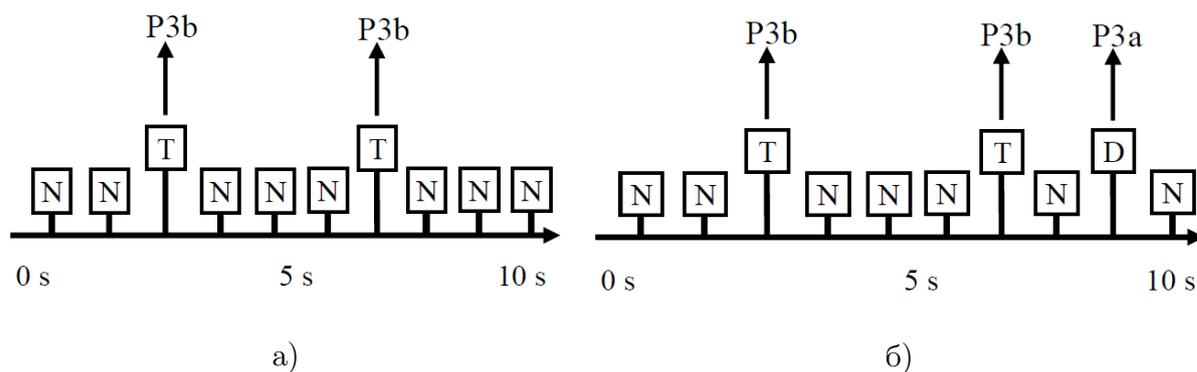


Рис. 4. Оригинальная (а) и трёхстимульная (б) парадигмы проведения экспериментов с порождением волн P300.

Межстимульный интервал. Амплитуда волны P3b прямо пропорциональна продолжительности межстимульного интервала (периода времени между двумя последовательными воздействиями стимулов).

Привыкание. Амплитуда волны P3a снижается с течением времени, поскольку из-за воздействия большого количества отвлекающих стимулов данное событие становится ожидаемым для испытуемого. В то же время амплитуда волны P3b практически не подвержена влиянию этого фактора.

Степень концентрации. Амплитуда волны P3b в большой мере зависит от степени концентрации пользователя. Более детально, волны P3b полностью исчезают, если пользователь не вовлечен в активное выполнение заданий. В то же время волны P3a не подвержены влиянию данного фактора.

Сложность заданий. Латентность волны P3b прямо пропорциональна сложности выполняемого задания, в то время как амплитуда обратно пропорционально этой величине. К примеру, целевые стимулы, сильно отличающиеся от нецелевых, ведут к более высокой амплитуде волны P3b по сравнению со случаем слабых отличий между целевыми и нецелевыми стимулами. Другой эффект наблюдается для волн P3a. Повышение сложности задачи по разделению целевых и нецелевых стимулов в трёхстимульной парадигме ведёт к повышению амплитуды волн P3a.

4 Методы обработки данных ЭЭГ

После получения данных при помощи электроэнцефалографа необходимо применение алгоритма, позволяющего определить желаемое для пользователя действие. Входными данными для этого алгоритма являются сигналы ЭЭГ, регистрируемые в процессе демонстрации стимулов. В большинстве существующих на текущий момент исследований по данной тематике задача классификации сигналов разбивается на три большие подзадачи: (1) предобработка сигнала (в целях удаления шумовых компонент); (2) формирование признакового пространства и (3) классификация объектов в построенном признаковом пространстве. Необходимо отметить, что наибольшее влияние на итоговое качество классификации оказывает влияние то, насколько успешно была решена задача формирования признакового пространства. Общая схема работы нейрокомпьютерных интерфейсов представлена на рис. 5.



Рис. 5. Общая схема работы нейрокомпьютерных интерфейсов.

4.1 Предобработка

Предобработка сигнала проводится с целью удаления артефактов (спонтанные сокращения мышц, моргание и т. п.), а также нейтрализации имеющихся шумовых компонент. Кроме того, зачастую интересующая информация содержится в определённом диапазоне частот, а остальные компоненты являются малоинформативными.

1°. Удаление постоянного амплитудного смещения

Постоянное амплитудное смещение (англ. *direct current offset, DC offset*, постоянное смещение потока) — отклонение волновой формы относительно оси нулевого уровня сигнала. Амплитудное смещение, наблюдаемое в электроэнцефалограмме, может быть разложено на две основные составляющие: постоянное смещение, возникающее из-за технических особенностей передачи данных, и смещение, возникающее из-за взаимодействия электрической цепи с потенциалом тела.

2°. Полосовая фильтрация

Как было упомянуто выше, в электроэнцефалограмме здорового человека выделяют несколько характерных составляющих электрических колебаний, называемых ритмами, различающихся частотным диапазоном. С целью выявления компонент, отвечающих соответствующим ритмам, применяются методы фильтрации в заданном диапазоне частот. Диапазон частот выбирается с учетом априорной информации о ритмах.

Фильтры нижних частот (англ. *low-pass filter, LPF*) называется тип фильтров, эффективно пропускающих частотный спектр сигнала ниже некоторой частоты (т.н. *частоты среза*) и уменьшающих (подавляющих) частоты сигнала выше этой частоты. Степень подавления каждой частоты зависит от вида фильтра. *Фильтр верхних частот* (англ. *high-pass filter, HPF*), напротив, пропускает частоты выше частоты среза и подавляет низкие частоты.

3°. Робастное преобразование

Одним из эффективных методов снижения влияния артефактов, имеющих место в данных ЭЭГ, является робастное преобразование данных для каждого сенсора. Для каждого электрода вычисляются значения перцентилей среза (см. рис. 6), затем значения, лежащие ниже или выше полученных значений, замещаются соответствующими значениями.

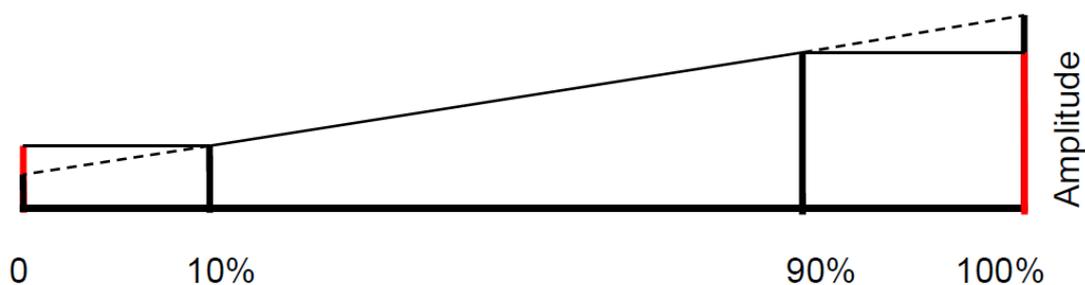


Рис. 6. Принцип работы робастного преобразования данных.

4°. Отбор электродов

Современные электроэнцефалографы оснащены десятками электродов, однако информация, получаемая при помощи такого количества сенсоров, является избыточной. Кроме того, увеличение числа электродов ведёт к повышению стоимости устройства и времени на подготовку к использованию, что является недопустимым для электроэнцефалографов, разработанных для коммерческого использования. В связи с этим в современных исследованиях по тематике нейрокомпьютерных интерфейсов наиболее распространены два подхода к решению данной проблемы:

- 1) выбор электродов с учётом априорных знаний о локализации компонент сигнала на скальпе;
- 2) использование методов отбора признаков.

4.2 Построение признакового пространства

Применение классических методов распознавания в классе задач нейрокомпьютерных интерфейсов малоэффективно в силу множества причин, среди которых высокая степень зашумлённости данных, высокая размерность пространства, а также многомерность самих сигналов и т. п. В связи с этим этап построения признакового пространства является самым важным в процессе решения задачи. Проблема заключается в том, что не существует единого метода поиска нового признакового пространства. Каждый исследователь сталкивается с необходимостью поиска признакового пространства для эффективного решения конкретной поставленной задачи с использованием конкретного оборудования.

1°. Слепое разделение источников

Методы слепого разделения источников (англ. *blind source separation*) основаны на предположении о том, что регистрируемые сигналы для мультиканального устройства являются смесью сигналов из различных источников, и предпринимают попытку выделить исходные источники с учётом некоторых предположений об их природе. Классическим примером задачи, иллюстрирующей функциональность данных методов, является «задача коктейльной вечеринки» (англ. *cocktail party problem*). Предполагается, что фиксируемые сигналы $X(t) = [x^1(t), \dots, x^{N_e}(t)]$ с использованием N_e сенсоров являются линейными комбинациями p исходных сигналов $S(t) = [s^1(t), \dots, s^p(t)]$:

$$X(t) = AS(t),$$

где $A \in \mathbb{R}^{N_e \times p}$ – неизвестная *смешивающая* матрица. Отметим, что для успешного решения задачи необходимо выполнения условия $N_e \geq p$. Метод слепого разделения источников производит поиск соответствующей *разделяющей* матрицы W , наилучшим образом оценивающей исходные сигналы:

$$\widehat{S}(t) = WX(t),$$

где $\widehat{S}(t)$ – оценка компонент источников $S(t)$. Кроме того, есть возможность оценки смешивающей матрицы A и последующей реконструкции исходных данных.

Метод главных компонент. Метод главных компонент (англ. *principal component analysis, PCA*) – метод поиска линейного преобразования данных путём максимизации дисперсии преобразованных данных. Задача может быть решена с использованием собственных векторов эмпирической матрицы ковариаций $X^T X$:

$$X^T X \alpha = \lambda \alpha,$$

где α – собственный вектор матрицы, отвечающий собственному значению λ . Набор собственных векторов образует ортогональный базис, в котором представляются исходные данные. В случае отсортированных в порядке убывания собственных значений большая часть вариации данных будет сосредоточена в первых координатах, что позволяет перейти к пространству меньшей размерности.

Метод независимых компонент. Метод независимых компонент (англ. *independent component analysis, ICA*) — метод, который может быть применен к произвольному набору случайных величин с целью нахождения линейного преобразования, максимизирующего статистическую независимость результирующих компонент. В то время как метод главных компонент опирается лишь на статистические моменты второго порядка, метод независимых компонент может быть назван его обобщением. В [3] данный метод определяется как оптимизационная задача минимизации совместной информации компонент источников. В упомянутом исследовании был представлен эффективный алгоритм вычисления негауссовости, напрямую связанной со статистической независимостью.

При использовании в задачах классификации волн Р300 метод независимых компонент показал способность изолировать данный тип волн в качестве компонент источников, упомянутых выше.

Существует множество различных реализаций метода независимых компонент, отличающихся в том числе используемым определением независимости компонент источников. По результатам сравнения нескольких ICA алгоритмов [3], используемых в исследованиях нейрокомпьютерных интерфейсов, для применения в данной работе был выбран алгоритм *FastICA* [5], продемонстрировавший хорошие результаты и использующий коэффициент эксцесса в качестве меры негауссовости.

Коэффициент эксцесса является мерой остроты пика распределения случайной величины и определяется формулой

$$\gamma_2 = \frac{\mathbb{E}[(X - \mathbb{E}X)^4]}{(\mathbb{D}X)^2} - 3.$$

Значение данного коэффициента позволяет проводить сравнение распределения некоторой случайной величины и нормального распределения, поскольку коэффициент эксцесса нормального распределения равняется нулю. Положительное значение коэффициента эксцесса означает, что большая часть дисперсии сигнала является результатом значимых, однако редко имеющих место отклонений, тем самым порождая распределение с «тяжелыми» хвостами. Алгоритм *FastICA* проводит поиск источников, отвечающих экстремуму коэффициента эксцесса.

2°. Морфологические признаки

Морфологические признаки описывают изменения амплитуд нейрофизиологических сигналов, происходящие в течение определённого временного промежутка. Часто используемая стратегия разделения фоновой активности и волн Р300 состоит в применении фильтра низких частот или фильтра с некоторой полосой пропускания с последующим возможным прореживанием сигнала, поскольку большая часть компоненты волны Р300 сконцентрирована именно в области низких частот, а потому описанная процедура позволяет нейтрализовать влияние избыточной информации. Помимо прочего, это также ведёт к снижению размерности сигнала.

Пусть имеется сигнал $x = [x_1, \dots, x_T]$. Для описания формы сигнала могут быть вычислены морфологические признаки, используемые отдельно или совместно с другими признаками. Некоторые из них перечислены ниже.

- **Амплитуда** — максимальное значение сигнала: $x_{max} = \max_{t=1, \dots, T} \{x_t\}$.
- **Латентность** — момент регистрации максимального значения сигнала для вызванных потенциалов: $t_{max} = \arg \max_{t=1, \dots, T} \{x_t\}$, где x регистрируется в течение фиксированного промежутка после выделения стимула.
- **Отношение латентность/амплитуда**: $LAR = \frac{t_{max}}{x_{max}}$.
- **Абсолютная амплитуда**: $AAMP = \max_{t=1, \dots, T} |x_t|$.
- **Абсолютное отношение латентность/амплитуда**: $ALAR = \frac{\arg \max_{t=1, \dots, T} |x_t|}{\max_{t=1, \dots, T} |x_t|}$.
- **Положительная область** — сумма положительных значений сигнала:
$$PAR = \sum_{t=1}^T \frac{x_t + |x_t|}{2}.$$
- **Отрицательная область** — сумма отрицательных значений сигнала:
$$NAR = \sum_{t=1}^T \frac{x_t - |x_t|}{2}.$$
- **Межпиковая разность**: $PP = x_{max} - x_{min}$, где x_{max} и x_{min} — максимальное и минимальное значения сигнала соответственно.
- **Межпиковое расстояние**: $PPT = t_{max} - t_{min}$.

3°. Преобразование Фурье

Зачастую анализ сигналов проводится при помощи разложения на «базисные» функции, каждая из которых отвечает некоторой частоте. Таким образом можно проанализировать степень выраженности колебаний некой частоты. В частности, преобразование Фурье использует в качестве базисных функций синусоиды. Для дискретных сигналов, имеющих место в задаче построения нейрокомпьютерного интерфейса, применяется дискретное преобразование Фурье (ДПФ).

Пусть имеется дискретный сигнал $x = [x_0, \dots, x_{N-1}]$. Тогда его можно представить в виде линейной комбинации дискретных синусоид следующего вида:

$$x_n = \sum_{k=0}^{\frac{N}{2}} C_k \cos \frac{2\pi k(n + \phi_k)}{N} = \sum_{k=0}^{\frac{N}{2}} A_k \cos \frac{2\pi kn}{N} + \sum_{k=0}^{\frac{N}{2}} B_k \sin \frac{2\pi kn}{N}, \quad n = \overline{0, N-1}.$$

Для каждого сигнала можно однозначно определить коэффициенты A_k, B_k , называемые *спектром* сигнала. Получение коэффициентов при имеющемся сигнале называется *прямым преобразованием Фурье*, в то время как обратный процесс, синтез сигнала по имеющимся коэффициентам, называется *обратным преобразованием Фурье*. Наиболее часто используется *быстрое преобразование Фурье (БПФ)*, позволяющее выполнять преобразования значительно быстрее за счёт наличия повторяющихся значений при вычислениях в силу периодичности функции синуса.

По аналогии можно произвести подобное разложение и для двумерного сигнала, при этом непосредственное вычисление двумерного ДПФ по полученным формулам требует огромных вычислительных затрат. Однако можно показать, что двумерное ДПФ обладает свойством сепарабельности, то есть его можно вычислить последовательно по двум измерениям.

Отметим также, что преобразование Фурье является чувствительным к шуму.

4°. Вейвлет-преобразование

Вейвлет-преобразование — интегральное преобразование, которое представляет собой свертку вейвлет-функции, обладающей рядом характерных свойств, с сигналом. По аналогии с преобразованием Фурье происходит некое разло-

жение исходного сигнала. Для дискретных сигналов используется дискретное вейвлет-преобразование.

Дискретное вейвлет-преобразование осуществляется путём применения набора фильтров. Сигнал подвергается действию фильтра низких частот с импульсным откликом g и фильтра высоких частот с импульсным откликом h , в результате чего могут быть получены т.н. *коэффициенты аппроксимации* и *детализирующие коэффициенты* соответственно. После этого каждый из наборов коэффициентов прореживается в два раза. Кроме того, данное разложение может быть повторено с дальнейшим прореживанием коэффициентов после низкочастотной и высокочастотной фильтрации. Данный процесс может быть представлен в виде двоичного дерева. Схема действия одно- и трёхуровневого дискретного вейвлет-преобразования приведена на рис. 7.

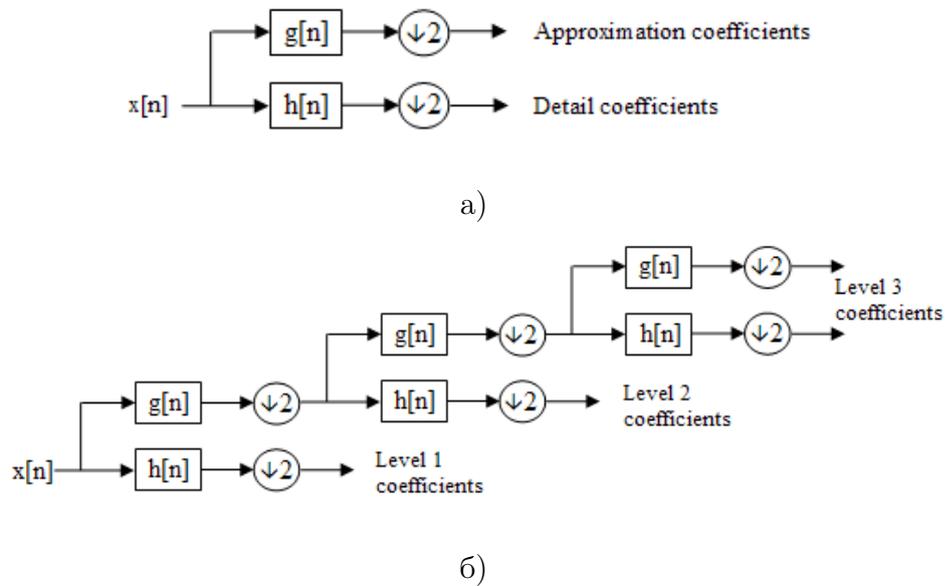


Рис. 7. Схема действия одно- (а) и трёхуровневого (б) дискретного вейвлет-преобразования.

5°. Общий пространственный фильтр

Общий пространственный фильтр (англ. *common spatial pattern filter, CSP*) реализует метод декомпозиции многоканального ЭЭГ сигнала, основанный на обучении по прецедентам.

Рассматривается задача классификации многомерных сигналов на два класса. Целью метода является разложение исходного сигнала на аддитивные составляющие таким образом, чтобы максимизировать дисперсию первых компонент и минимизировать дисперсию последних для объектов первого класса и добиться обратной ситуации для объектов второго класса. Матрица декомпозиции может быть найдена в результате одновременной диагонализации выборочных матриц ковариации для каждого из классов. В результате может быть сформирован вектор характерных признаков путём соединения значений некоторого количества первых и последних компонент разложенного сигнала.

Метод также может быть обобщён для применения к задачам с количеством классов, большим двух, путём разбиения исходной задачи на бинарные подзадачи с использованием схем «один против одного» или «один против всех».

4.3 Классификация

После построения искомого признакового пространства алгоритм, используемый для классификации преобразованных объектов, играет не столь значительную роль. После предобработки и преобразования исходных данных проводится обучение классификатора, после чего обученный классификатор может принимать решение о наличии либо отсутствии волн Р300 и, как следствие, о необходимости выполнять действие, предписанное стимулом. Наиболее часто в исследованиях по тематике *BCI* используются описанные ниже типы классификаторов. Более подробное описание данных алгоритмов может быть найдено в [11].

1°. Байесовский классификатор

Байесовский классификатор — широкий класс алгоритмов классификации, основанный на принципе максимума апостериорной вероятности. Для классифицируемого объекта вычисляются функции правдоподобия каждого из классов, по ним вычисляются апостериорные вероятности классов. Объект относится к тому классу, для которого апостериорная вероятность максимальна.

Байесовский подход к классификации основан на теореме, утверждающей, что если плотности распределения каждого из классов известны, то искомым алгоритм

можно выписать в явном аналитическом виде. Более того, этот алгоритм оптимален, то есть обладает минимальной вероятностью ошибок.

На практике плотности распределения классов, как правило, не известны. Их приходится оценивать (восстанавливать) по обучающей выборке. В результате байесовский алгоритм перестаёт быть оптимальным, так как восстановить плотность по выборке можно только с некоторой погрешностью. Зачастую в исследованиях по тематике создания нейрокомпьютерного интерфейса в качестве функции правдоподобия для объекта используется смесь нормальных распределений.

2°. Линейный дискриминант Фишера

Линейный дискриминант Фишера (ЛДФ) — особый вариант байесовского классификатора. Рассмотрим задачу классификации на два класса. Предполагается, что обучающая выборка составлена таким образом, что классы распределены по нормальному закону, а матрицы ковариаций классов равны. Простота классификации линейным дискриминантом Фишера — одно из достоинств алгоритма: в случае с двумя классами в двумерном признаковом пространстве разделяющей поверхностью будет прямая. Если классов больше двух, то разделяющая поверхность будет кусочно-линейной.

Данный метод классификации не требует больших вычислительных затрат, а потому является распространённым в приложениях, функционирующих в режиме реального времени.

3°. Нейронные сети

Нейронные сети широко используются во многих приложениях, решающих задачу классификации, поскольку обладают гибкостью. Классическая модель нейронной сети состоит из узлов, называемых *нейронами*, и связей между ними, называемых *синапсами*, при этом узлы организованы в т.н. *слои*. Входной слой получает вектор описания объекта, подвергаемого классификации, выходной слой принимает итоговое решение о классификации данного объекта. Помимо двух упомянутых слоёв в нейронной сети также может присутствовать некоторое количество *скрытых* слоёв. Каждому из синапсов ставится в соответствие некоторое вещественное число,

называемое *весом*, используемое при вычислении входных данных для следующего слоя нейронов. Каждому из нейронов ставится в соответствие некоторая *функция активации*, применяемая к сумме данных всех синапсов, оканчивающихся в данном нейроне, с целью получения выхода данного нейрона.

Задача обучения нейронной сети состоит в настройке весов синапсов, имеющих место в используемой модели. Одной из широко применяемых моделей нейронных сетей в задачах построения нейрокомпьютерных интерфейсов является сеть прямого распространения, обучаемая при помощи метода обратного распространения ошибки (англ. *backpropagation*).

4°. Метод опорных векторов

Метод опорных векторов (англ. *support vector machine, SVM*) — набор схожих алгоритмов обучения с учителем, принадлежащий к семейству линейных классификаторов. Особым свойством метода опорных векторов является непрерывное уменьшение эмпирической ошибки классификации и увеличение зазора, поэтому метод также известен как метод классификатора с максимальным зазором. Кроме того, на положение разделяющей гиперплоскости в действительности оказывает влияние небольшая часть объектов обучающей выборки. Метод также обобщается на случай нелинейной разделяющей поверхности.

Зачастую используется в исследованиях по тематике *BCI* в силу сводимости к задаче квадратичного программирования и последующей эффективности вычислений.

5°. Метод k ближайших соседей

Метод k ближайших соседей (англ. *k-nearest neighbor algorithm, kNN*) — метод автоматической классификации объектов. Основным принципом метода ближайших соседей является тот факт, что объекту приписывается метка класса, наиболее распространённого среди k наиболее близких в некотором смысле объектов обучающей выборки, где k — параметр алгоритма.

Таким образом, если в процессе формирования признакового пространства удалось некоторым образом локализовать объекты каждого из классов в некоторой области пространства, данный метод может быть использован для классификации

преобразованных объектов. Кроме того, среди достоинств данного метода следует упомянуть вычислительную простоту, что делает его простым для использования в приложениях, функционирующих в режиме реального времени.

4.4 Критерий качества

Важным аспектом всякой системы *BCI* является достигаемая скорость коммуникации. В системах, основанных на распознавании волн Р300, данная характеристика зависит от межстимульного интервала, количества различных стимулов, качества работы классификаторов. Чтобы проследить зависимость от перечисленных факторов, будем использовать в качестве метрики для оценивания скорости коммуникации скорость передачи информации (битрейт). Битрейт оценивает количество бит, передаваемых испытуемым системе в единицу времени. Данная характеристика широко используется для оценки работы нейрокомпьютерных интерфейсов, в том числе и не основанных на волнах Р300.

Определим матрицу ошибок для задачи классификации на два класса, разделив эпохи для целевых и нецелевых стимулов на верно и неверно классифицированные:

- a — количество **верно** классифицированных **нецелевых** эпох;
- b — количество **неверно** классифицированных **нецелевых** эпох;
- c — количество **неверно** классифицированных **целевых** эпох;
- d — количество **верно** классифицированных **целевых** эпох.

| | | Предсказанный тип стимула | |
|----------------------|-----------|---------------------------|---------|
| | | Нецелевой | Целевой |
| Реальный тип стимула | Нецелевой | a | b |
| | Целевой | c | d |

Таблица 2. Матрица ошибок для задачи распознавания волн Р300.

Таким образом, можно составить таблицу 2. *Чувствительностью* (англ. *true positive rate*, *TPR*) называется доля верно классифицированных целевых эпох, *специфичностью* (англ. *false positive rate*, *FPR*) — доля неверно классифицированных

нецелевых эпох. Данные величины могут быть вычислены по следующим формулам:

$$TPR = \frac{d}{c + d},$$

$$FPR = \frac{b}{a + b}.$$

Положим $n_1 = c + d$ — количество целевых эпох, $n_2 = a + b$ — количество нецелевых эпох. Тогда битрейт может быть вычислен по следующей формуле:

$$BR = \frac{d}{n_1 + n_2} \times \frac{60}{ISI} \times \log_2(N_{st}),$$

где ISI — межстимульный интервал (сек), т.е. промежуток времени между демонстрацией двух последовательных стимулов, N_{st} — количество различных визуальных стимулов, используемых в эксперименте.

Кроме указанных величин, *точность* системы может быть вычислена по формуле:

$$Accuracy\% = \frac{a + d}{a + b + c + d} \times 100\%.$$

Указанные величины широко используются в литературе по исследуемой тематике для оценки качества функционирования системы. В связи с этим будем использовать совокупность указанных характеристик для оценки эффективности интерфейса.

5 Проведение эксперимента

5.1 Парадигма эксперимента

Как правило, в исследованиях на основе визуальных стимулов используется следующая схема получения данных:

- Испытуемому в течение t_1 секунд демонстрируется визуальный стимул либо ментальное задание, которое предстоит выполнить. Значение t_1 варьируется для различных типов исследований.
- В течение t_2 секунд испытуемый сосредотачивает внимание на визуальном стимуле либо выполняет указанное ментальное задание. Кроме того, в процессе этого действия происходит запись данных. Значение t_2 варьируется для различных типов исследований.
- Визуальный стимул перестаёт демонстрироваться испытуемому, проводится краткая пауза для восстановления расслабленного состояния и подготовки к следующей итерации.

После изучения материалов по исследуемой тематике и различных видов парадигм, используемых для тестирования применимости разработанных систем управления, было принято решение провести две серии экспериментов, использующих различные виды визуальных стимулов.

Получение данных для каждого из двух испытуемых производилось следующим образом. Испытуемый располагался лицом к монитору компьютера с устройством *Emotiv EPOC*, расположенным на голове. На экране монитора было изображено квадратное поле, разбитое на 100 равных квадратов прямыми, параллельными его сторонам, путём деления каждой стороны на 10 равных отрезков. Каждый из квадратов является возможным положением курсора на экране компьютера. Целью испытуемого являлось управление курсором в виде голубого квадрата, расположенного на экране компьютера, от начального до обозначенного конечного положения путем перемещения сначала по горизонтали, а затем — по вертикали. Четыре визуальных стимула выделялись на экране последовательно случайным образом, в каждый момент времени было выделено не более одного визуального стимула. В первой

серии экспериментов в качестве визуальных стимулов выступали изображения стрелок, отвечающих четырём возможным направлениям движения курсора (вверх, вниз, влево, вправо); во второй серии экспериментов использовались текстовые надписи, описывающие одно из указанных направлений движения. Внешний вид используемого поля и визуальных стимулов в двух сериях экспериментов изображен на рис. 8. Испытуемому требовалось сконцентрировать внимание на стимуле, отвечающем желаемому направлению движения (целевом стимуле с вероятностью появления 25%), и игнорировать остальные стимулы, отвечающие нежелательным направлениям движения курсора (нецелевые стимулы с вероятностью появления 75%).

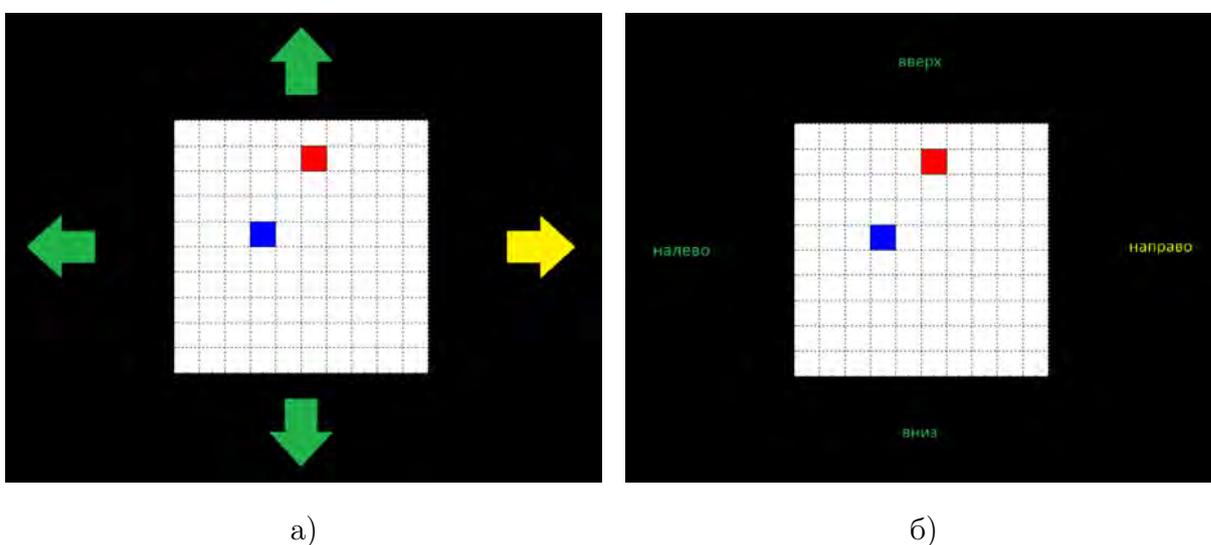


Рис. 8. Поле и визуальные стимулы, изображённые на экране компьютера в процессе проведения серий экспериментов с различными видами стимулов.

Пробой назовем последовательность из выделения некоторого визуального стимула в течение 250 мс, а также последующие 1250 мс, необходимые для обработки, классификации данных, генерации команды и выполнения перемещения курсора. Межстимульный интервал при проведении эксперимента равнялся 2500 мс, включая время, необходимое на обработку и классификацию данных. Назовём *сессией* последовательность проб, предпринятых для достижения курсором целевого положения.

Запись ЭЭГ осуществлялась с частотой дискретизации 128 Гц (с внутренней частотой дискретизации устройства 2048 Гц и последующей первичной обработкой) при помощи устройства *Emotiv EPOC*. При записи данных устройство находилось в двух

различных положениях: положении по умолчанию и инверсированном положении. В положении по умолчанию были использованы данные 10 сенсоров (F3, FC5, T7, P7, O1, O2, P8, T8, FC6, и F4), поскольку данное подмножество обеспечивает наилучшую нейтрализацию компонент, не отвечающих за волны P300, а также включает сенсоры O1, O2, при помощи которых могут быть зафиксированы некоторые из компонент волн P300 [4]. В инверсированном положении были использованы данные 8 сенсоров (FC6, F4, P8, AF4, AF3, F3, P7 и FC5), поскольку они покрывают центральную часть скальпа, которая считается областью, участвующей в генерации волн P300. Положения указанных сенсоров на голове человека изображены на рис. 9.

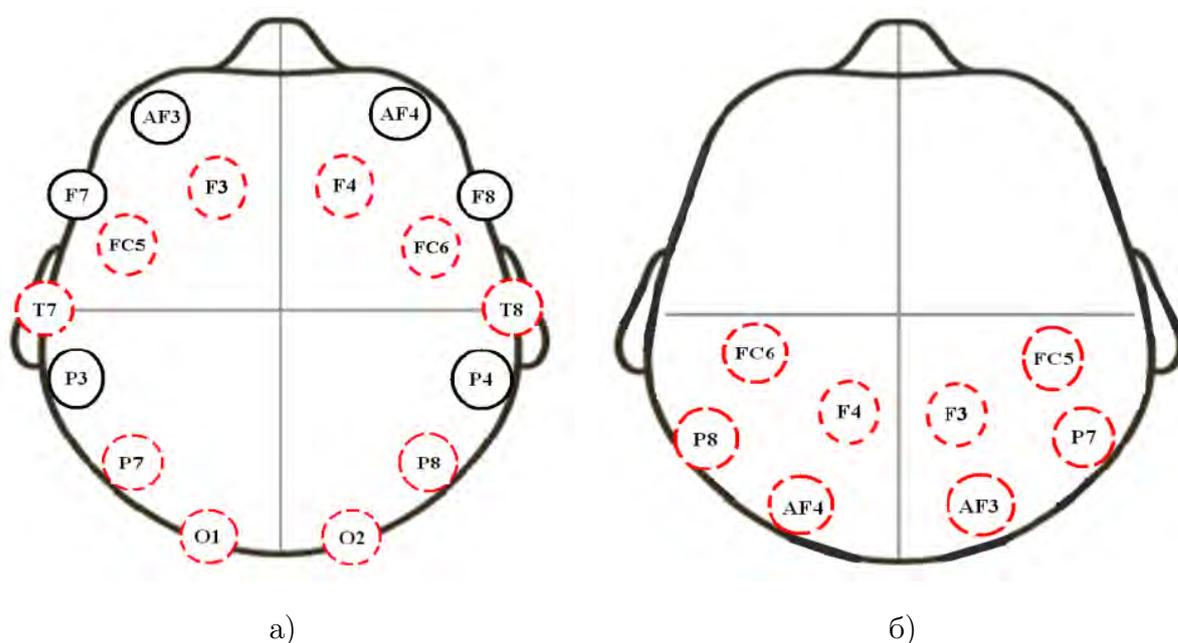


Рис. 9. Положения сенсоров для положения устройства по умолчанию (а) и инверсированного положения (б).

5.2 Схема эксперимента

Наиболее распространённая схема эксперимента в исследованиях нейрокомпьютерных интерфейсов, основанных на выявлении волн P300, предполагает, что ответ на целевой стимул не зависит от конкретного стимула, в связи с этим классификация является эффективным методом распознавания целевых и нецелевых стимулов. Тем не менее, некоторые исследования, в частности [4], описывают применение отдельных классификаторов и демонстрируют, что таким образом производительность системы

может быть повышена. В связи с этим было решено применить оба подхода и сравнить полученные результаты.

Схема эксперимента для каждого испытуемого состояла из двух частей: предобучения и тестирования в режиме реального времени. В процессе предобучения пользователю необходимо произвести предписанную последовательность действий, описанную ниже, позволяющую собрать некоторое количество данных, используемых для обучения классификатора. В процессе тестирования в режиме реального времени пользователю необходимо производить похожую процедуру, однако полученные данные для каждого из стимулов обрабатываются и классифицируются при помощи предобученного классификатора в тот же момент времени, а также принимается решение о наличии или отсутствии выолны Р300 и, соответственно, необходимости перемещения курсора в соответствующем направлении.

Для функционирования обоих подходов необходимо проведение процедуры предобучения отдельно для каждого испытуемого (в силу физиологических различий, ненадёжной фиксации устройства на голове человека, изменения потенциала тела человека с течением времени и т. п.). Предобучение проводится по следующей схеме:

- Раунд представляет из себя следующую последовательность действий. В течение раунда каждый из четырех визуальных стимулов, отвечающих возможным направлениям движения курсора, выделяется в течение 250 мс, затем следует период ожидания продолжительностью 2250 мс.
- Испытуемый концентрирует внимание на фиксированном визуальном стимуле в течение N раундов. Было проведено несколько серий экспериментов для различных значений N , в частности, $N = 10, 15, 20, 30$.
- После N раундов процесс останавливается на 10 секунд для восстановления расслабленного состояния и подготовки к следующей серии раундов, а затем проводятся раунды для следующего визуального стимула до тех пор, пока не состоялись раунды для всех видов стимулов.
- Таким образом, обучающая сессия состоит из $4N$ раундов записи ЭЭГ, содержащих $4N$ эпох целевых данных и $12N$ эпох нецелевых данных, где *эпохой* мы будем называть промежуток времени, содержащий выделение одного из

визуальных стимулов и последующий период ожидания вплоть до выделения последующего визуального стимула.

- Кроме того, также проводится N эпох для записи данных, отвечающих спокойному состоянию испытуемого, т.е. испытуемый расслаблен, а визуальные стимулы не выделяются.
- Таким образом, количество нецелевых эпох составляет $13N$. 75% имеющихся данных используются для обучения классификатора для разделения целевых и нецелевых данных. Остальные 25% данных используются для настройки параметров классификатора в процессе обучения.

Для схемы с использованием отдельных классификаторов используется аналогичный сценарий, однако число раундов для каждого направления удваивается.

6 Предлагаемый подход

6.1 Предобработка

Перед обучением классификатора данные были подвергнуты предобработке. Последовательность действий, применённых к данным, описана ниже.

Центрирование данных. В первую очередь все данные, полученные с каждого электрода, были центрированы с целью нейтрализации постоянного амплитудного смещения. Затем среднее значение сигналов, полученных с электродов сравнения, было использовано для референциального монтажа данных. В положении устройства по умолчанию в качестве электродов сравнения были использованы позиции AF3 и AF4, в инверсированном — O1 и O2.

Выделение отдельных проб. После этого из полученных данных были выделены отдельные пробы продолжительностью 1500 мс. Начало пробы совпадало с началом выделения визуального стимула на экране компьютера, конец пробы приходился на момент через 1500 мс после начала выделения стимула (250 мс выделения визуального стимула и 1250 мс ожидания). Таким образом, для дальнейшей обработки и определения наличия волн P300 имеются данные, представленные в виде потенциалов, зарегистрированных для 192 моментов времени для каждого из сенсоров после выделения каждого из визуальных стимулов.

Фильтрация. Отметим, что используемый электроэнцефалограф подвергает регистрируемые данные внутренней фильтрации с полосой пропускания 0.16–43 Гц.

Были проведены эксперименты с использованием различных типов низкочастотных цифровых фильтров для обработки полученных сигналов, в частности, фильтра Чебышева 4-го порядка 1-го рода, фильтра Баттерворта и эллиптического фильтра с частотой среза 30 Гц.

Метод независимых компонент. К данным ЭЭГ, подвергнутым фильтрации, был применен метод независимых компонент для извлечения независимых источников. Была использована реализация алгоритма *FastICA* для MATLAB. Описание

алгоритма было представлено в предыдущих разделах. Более подробно алгоритм описан в [5].

6.2 Отбор признаков

В исследовании [6] был применен метод с использованием нечетких регуляторов (англ. *fuzzy control method*) для отбора признаков, наиболее похожих на волны P300, для дальнейшей классификации. Другие исследования используют неавтоматический метод отбора признаков. Поскольку в данной работе используется коммерческое *BCI*-устройство с высоким уровнем шума в получаемых данных, нет возможности ожидать, что среди полученных независимых компонент будет присутствовать близкая к волне P300 наподобие полученных в исследовании [6]. Кроме того, данный метод существенно увеличивает время обработки данных. В исследовании [7] показано, что результирующие компоненты ICA, отличные от волн P300, практически неотличимы для целевых и нецелевых проб, поскольку они являются компонентами одних и тех же источников артефактов в одинаковых условиях. Для первого подхода к компонентам, полученным при помощи метода независимых компонент, применяется дискретное вейвлет-преобразование 3-го порядка, поскольку коэффициенты аппроксимации позволяют некоторым образом описать форму волны зарегистрированного сигнала. Для второго подхода преобразование применяется непосредственно к данным ЭЭГ. Для обоих подходов был использован вейвлет Добеши, поскольку он широко распространён в литературе для подобных целей. Результирующие коэффициенты аппроксимации были использованы в качестве признаков и были конкатенированы в единые вектора. Результирующая размерность признакового представления объектов равнялась $N_e \times N_f$, где N_e — количество сенсоров, N_f — количество вычисленных признаков для сигнала, регистрируемого при помощи одного сенсора. Помимо аппроксимирующих коэффициентов, были также использованы описанные в предыдущих разделах морфологические признаки. С учётом выбора одного из указанных подмножеств электродов имеем $N_e = 8$ или $N_e = 10$.

Далее отобранные признаки были центрированы и декоррелированы, т.е. подвергнуты преобразованию, обеспечивающему нулевое среднее значение каждого признака

и единичную матрицу ковариаций. Нормировочные константы вычислялись для каждого сенсора с учётом всех имеющихся в обучающей выборке данных, а затем также применялись к отложенной выборке. Отметим, что осуществление данной процедуры для отдельных проб без учёта остальной информации может уничтожить важную информацию об амплитуде имеющихся волн P300, в связи с этим необходимо учитывать данные всех зарегистрированных проб.

6.3 Классификация

После предобработки и отбора признаков, наиболее вероятно характеризующих наличие либо отсутствие волны P300, проводились обучение и настройка параметров классификатора. Как было упомянуто выше, данные центрированы и имеют единичную матрицу ковариаций. В качестве классификаторов были использованы нейронная сеть и линейный классификатор.

Применялась нейронная сеть прямого распространения с одним скрытым слоем. Структура подобного классификатора изображена на рис. 10. Отметим, что распределение данных, получаемых каждым из нейронов входного слоя сети, осуществлялось между всеми нейронами скрытого слоя. В качестве функций активации для нейронов скрытого и выходного слоев была использована функция гиперболического тангенса в соответствии с рекомендациями [13]. Поскольку метки классов соответствовали наличию и отсутствию волн P300, полученное итоговое значение являлось оценкой наличия волн данного типа. В соответствии с рекомендациями [18] считалось, что итоговое значение, превышающее 0.76, свидетельствовало о наличии волн P300, иное значение — об их отсутствии. Для обучения нейронной сети применялся метод обратного распространения ошибки.

В качестве алгоритма обучения линейного классификатора применялся SVM. Была использована реализация машины опорных векторов библиотеки *LibSVM*. Для алгоритма с общим для всех типов стимулов классификатором было использовано квадратичное ядро, в то время как для алгоритма с отдельными классификаторами была использована линейная версия *SVM*. Значение гиперпараметра C настраивалось при помощи отложенной выборки.

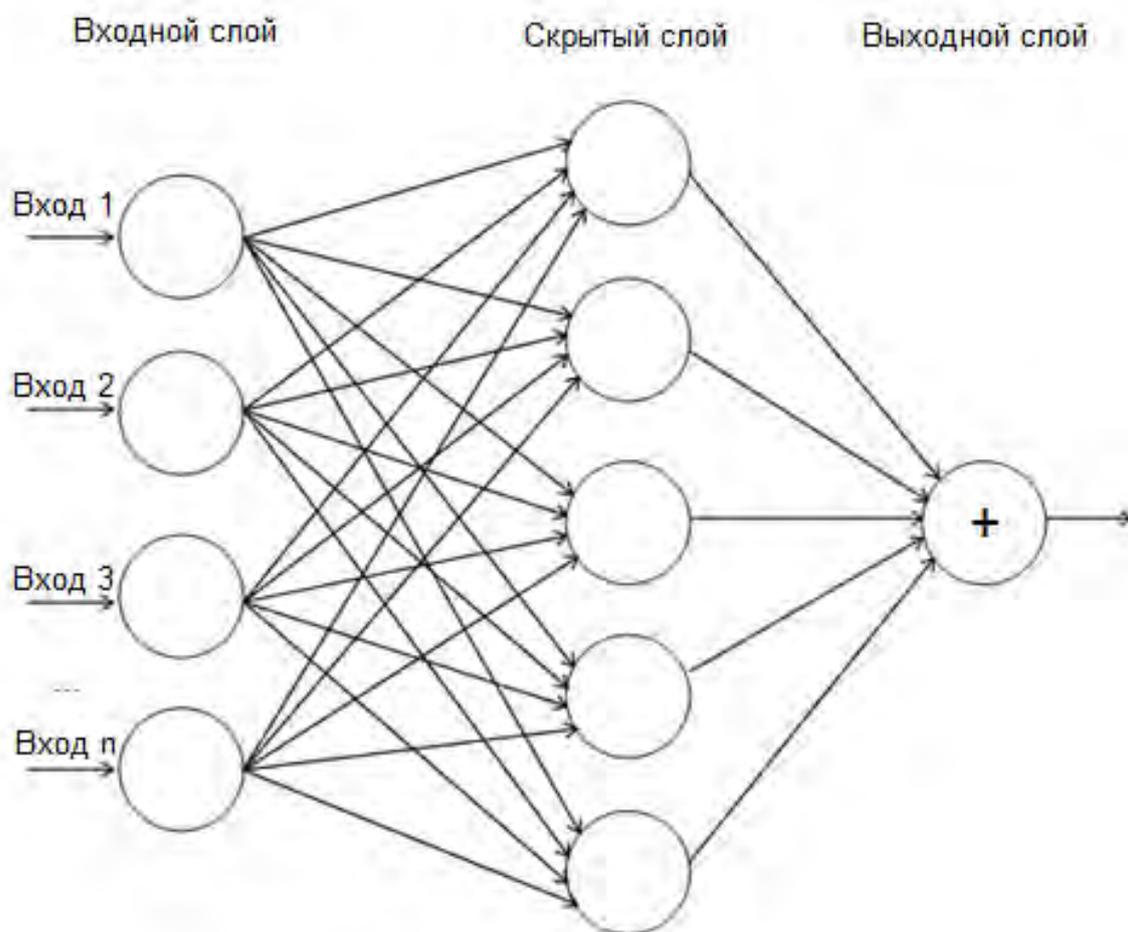


Рис. 10. Структура используемой модели нейронной сети.

Для подхода с применением общего классификатора обучающая выборка состояла из $4N$ целевых и $13N$ нецелевых эпох. В связи с высоким уровнем шума в данных было проведено усреднение по наборам из пяти эпох. Как было упомянуто выше, случайно выбранные 75% полученных объектов были использованы для обучения классификатора, в то время как оставшиеся 25% были использованы для настройки параметров.

Для подхода, использующего отдельные классификаторы, были обучены четыре различных линейных классификатора, отвечающих различным визуальным стимулам. В данном случае для каждого из классификаторов были доступны N целевых и $4N$ нецелевых эпох, а усреднение проводилось по наборам из 3 эпох.

6.4 Тестирование

После обучения классификатора необходим запуск процесса тестирования в режиме реального времени вручную. В течение этого времени ведётся запись данных ЭЭГ, при этом стимулы выделяются в случайном порядке в течение 250 мс с последующей паузой в течение 1250 мс. Данные, полученные в течение этого времени, подвергаются описанной процедуре предобработки и выделения признаков и дальнейшей классификации при помощи обученного классификатора. В случае принятия решения о наличии компоненты волн Р300 курсор перемещается в соответствующем направлении, в случае противоположного решения — процесс продолжается без перемещения курсора.

7 Результаты

7.1 Результаты с положением устройства по умолчанию

Как было упомянуто выше, при расположении устройства в позиции по умолчанию малое число электродов покрывают часть скальпа, отвечающую за генерацию волн P300. В таком положении наибольшее влияние данного эффекта может быть замечено только в данных, регистрируемых при помощи сенсоров O1 и O2. В связи с этим результаты экспериментов, отображённые в таблицах 3 и 4, демонстрируют неприемлемо низкие уровни точности классификации и чувствительности, а также недопустимо высокий уровень специфичности по сравнению с результатами, полученными для инверсированного положения.

| Количество раундов N | Чувствительность (TPR) | Специфичность (FPR) | Битрейт | Точность |
|---------------------------|---------------------------|------------------------|---------|----------|
| 10 | 24.04% | 42.63% | 2.88 | 49.04% |
| 15 | 25.96% | 41.99% | 3.11 | 50.02% |
| 20 | 26.21% | 41.67% | 3.12 | 50.36% |
| 30 | 26.92% | 41.35% | 3.24 | 50.84% |

Таблица 3. Результаты применения подхода с общим классификатором для положения устройства по умолчанию.

| Количество раундов N | Чувствительность (TPR) | Специфичность (FPR) | Битрейт | Точность |
|---------------------------|---------------------------|------------------------|---------|----------|
| 10 | 24.53% | 46.53% | 2.94 | 46.23% |
| 15 | 26.42% | 45.91% | 3.17 | 47.17% |
| 20 | 28.97% | 44.03% | 3.50 | 49.18% |
| 30 | 32.08% | 43.08% | 3.85 | 50.70% |

Таблица 4. Результаты применения подхода с отдельными классификаторами для положения устройства по умолчанию.

7.2 Результаты с инверсированным положением устройства

Было проведено несколько серий экспериментов с использованием различных парадигм. В таблицах 5 и 6 отображены наилучшие полученные результаты.

| Количество раундов N | Чувствительность (TPR) | Специфичность (FPR) | Битрейт | Точность |
|---------------------------|---------------------------|------------------------|---------|----------|
| 10 | 45.75% | 37.36% | 5.80 | 58.67% |
| 15 | 48.41% | 35.82% | 5.96 | 60.13% |
| 20 | 48.73% | 33.94% | 6.16 | 61.50% |
| 30 | 49.36% | 34.17% | 6.08 | 61.51% |

Таблица 5. Результаты применения подхода с общим классификатором для инверсированного положения устройства.

| Количество раундов N | Чувствительность (TPR) | Специфичность (FPR) | Битрейт | Точность |
|---------------------------|---------------------------|------------------------|---------|----------|
| 10 | 49.06% | 35.07% | 6.23 | 60.73% |
| 15 | 49.67% | 34.16% | 6.31 | 61.56% |
| 20 | 50.31% | 32.58% | 6.39 | 62.90% |
| 30 | 52.83% | 31.90% | 6.71 | 64.06% |

Таблица 6. Результаты применения подхода с отдельными классификаторами для инверсированного положения устройства.

7.3 Обсуждение и выводы

Полученные результаты для системы с инверсированным положением устройства демонстрируют, что точность классификации предложенного подхода сравнима с существующими на данный момент исследованиями в данной области, использующими схожее оборудование и условия проведения экспериментов. В частности, в [8] была достигнута точность 60% выявления волн P300 при использовании устройства *Emotiv EPOC*.

Для испытуемых значение чувствительности оказалось довольно низким. Таким образом, система распознавала приблизительную предполагаемую траекторию движения курсора, однако для распознавания непосредственно команды необходимо было ожидание в течение нескольких проб, как следствие, наблюдалось падение производительности системы. Тем не менее, приемлемое значение точности может быть достигнуто при низком значении специфичности. Высокое же значение данной характеристики дезориентирует пользователя и может привести к невозможности дальнейшего управления курсором, поскольку траектория в таких случаях радикально отличается от предполагаемой пользователем. Отметим, что полученные значения специфичности не уступают результатам, полученным в [9]. Предложенный в данной работе метод позволяет добиться лучших результатов по сравнению с подходом, предложенным в исследовании [12], при использовании *Emotiv EPOC*.

Кроме того, в результате экспериментов было отмечено, что использование изображений стрелок в качестве визуальных стимулов ведёт к лучшим результатам, нежели изображений надписей.

Наилучший результат был получен при применении подхода, использующего отдельные классификаторы для различных типов стимулов. Тем не менее, полученные результаты не свидетельствуют о том, что использование подхода отдельных классификаторов гарантирует лучший результат, нежели использование подхода с общим классификатором.

Более высокое качество функционирования разработанной системы может быть достигнуто путём решения следующих проблем:

Неточное расположение сенсоров. В инверсированном положении расположение электродов являлось приблизительным и, поскольку устройство было разработано для эксплуатации в позиции по умолчанию, некоторые из сенсоров ненадёжно крепились к голове испытуемого, не обеспечивая должного качества регистрируемого сигнала. Кроме того, изменились также и положения опорных электродов, тем самым оказав влияние на внутреннюю обработку получаемых данных в устройстве.

Малое количество сенсоров в области интереса. Как было упомянуто выше, в положении устройства по умолчанию сенсоры практически не покрывают часть скальпа, отвечающую за генерацию волн Р300. В инверсированном положении приблизительно не более шести электродов расположены в данной области, и, тем не менее, ни один из них не расположен в области, наиболее активно отвечающей за данный процесс.

Отношение сигнал-шум. Поскольку устройство не было разработано для исследовательских целей, нет возможности гарантировать должное качество изготовления его деталей и, тем самым, качества снимаемого сигнала.

Задержка при фиксации сигналов. Отсутствие возможности получения исходных данных ЭЭГ без использования разработанного для устройства программного обеспечения также ведёт к падению производительности системы. По информации производителя, передача данных производится с обеспечением задержки во времени, не превышающей 15 мс, что является причиной потери части информации.

8 Заключение

В рамках настоящей дипломной работы были изучены существующие подходы к решению задач построения нейрокомпьютерных интерфейсов. Был предложен метод построения нейрокомпьютерного интерфейса для управления динамическим объектом, а также проведено сравнение с аналогичными исследованиями последних лет.

В ходе данной работы были получены следующие основные результаты:

- Предложен метод классификации сигналов головного мозга в задаче управления курсором на экране компьютера с использованием общедоступного устройства *Emotiv EPOC*.
- Предложенный метод был протестирован при помощи программной реализации в системе MATLAB.
- Качество функционирования описанного подхода не уступает, а по некоторым параметрам превосходит существующие на сегодняшний день методы решения поставленной задачи с использованием схожего оборудования и условий проведения экспериментов.
- Разработанный алгоритм может быть также применен в задаче управления динамическим объектом реального мира.

Список литературы

1. *Farwell L.A., Donchin E.* Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. // *Electroencephalography & Clinical Neurophysiology*, Vol. 70, Issue 6, pp. 510-523, 1988.
2. *Sutton S., Braren M., Zubin J., John E.R.* Evoked-potential correlates of stimulus uncertainty. // *Science*, Vol. 150, Issue 700, pp. 1187-1188, 1965.
3. *Kachenoura A., Albera L., Senhadji L., Comon P.* ICA: A Potential Tool for BCI Systems. // *Signal Processing Magazine, IEEE*, Vol. 25, Issue 1, pp. 57-68, 2008.
4. *Rakotomamonjy A., Guigue V.* BCI Competition III: Dataset II- Ensemble of SVMs for BCI P300 Speller. // *Biomedical Engineering, IEEE Transactions*, Vol. 55, Issue 3, pp. 1147-1154, 2005.
5. *The FastICA algorithm package for MATLAB.* [HTML] (<http://research.ics.aalto.fi/ica/fastica/>).
6. *Piccione F., Giorgi F., Tonin P., Priftis K., Giove S., Silvoni S., Palmas G., Beverina F.* P300-based brain computer interface: reliability and performance in healthy and paralysed participants. // *Clin Neurophysiol*, Vol. 117, Issue 3, pp. 531-537, 2006.
7. *Wang S., James C.J.* Enhancing evoked responses for BCI through advanced ICA techniques. // *International Conference on Advances in Medical, Signal and Information Processing*, pp. 1-4, 2006.
8. *Ramírez-Cortés J.M., Alarcon-Aquino V., Rosas-Cholula G., Gomez-Gil P., Escamilla-Ambrosio J.* P-300 Rhythm Detection Using ANFIS Algorithm and Wavelet Feature Extraction in EEG Signals. // *Proceedings of the World Congress on Engineering and Computer Science*, Vol. 1, pp. 963-968, 2010.
9. *Kanoh S., Miyamoto K., Yoshinobu T.* A P300-based BCI System for Controlling Computer Cursor Movement. // *Conf Proc IEEE Eng Med Biol Soc.*, 2011.

10. *Jasper H.H.* The ten-twenty electrode system of the International Federation. // *Electroencephalogr Clin Neurophysiol*, Vol. 10, pp. 371-375, 1958.
11. *Воронцов К.В.* Математические методы обучения по прецедентам (теория обучения машин). [HTML] (<http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf>).
12. *Khemri N.A.* P300 Wave Detection Using a Commercial Non-invasive Eeg Sensor: Reliability and Performance in Control Applications. // Graduate College of the Oklahoma State University, 2012.
13. *LeCun Y., Bottou L., Genevieve B. Orr, Müller K.-R.* Efficient BackProp. / *Lecture Notes in Computer Science*, Vol. 1524, pp. 9-50, 2002.
14. *Amcalar A., Cetin M.* Design, Implementation and Evaluation of a Real-Time P300-based Brain-Computer Interface System. // *IEEE International Conference on Pattern Recognition*, pp. 117-120, 2010.
15. *Piccione F., Priftis K., Tonin P., Vidale D., Furlan R., Cavinato M., Merico A., Piron L.* Task and Stimulation Paradigm Effects in a P300 Brain Computer Interface Exploitable in a Virtual Environment: A Pilot Study. // *PsychNology Journal*, Vol. 6, Issue 1, p. 99, 2008.
16. *Hagen G.F., Gatherwright J.R., Lopez B.A., Polich J.* P3a from visual stimuli: Task difficulty effects. // *International Journal of Psychophysiology*, Vol. 59, Issue 1, pp. 8–14, 2006.
17. *Jones K.A., Porjesz B., Chorlian D., Rangaswamy M., Kamarajan C., Padmanabhapillai A., Stimus A., Begleiter H.* S-transform time-frequency analysis of P300 reveals deficits in individuals diagnosed with alcoholism. // *Clinical Neurophysiology*, Vol. 117, Issue 10, pp. 2128–2143, 2006.
18. *Hagan M.T., Demuth H.B., Beale M.H.* *Neural Network Design*. // Thompson Learning, USA, 1996.