

DOI: <https://doi.org/10.30898/1684-1719.2025.1.1>

УДК: 004.032.26, 621.396

УНИВЕРСАЛЬНЫЙ ПРОГРАММНО-АППАРАТНЫЙ КОМПЛЕКС ДЛЯ УПРАВЛЕНИЯ РОБОТИЗИРОВАННЫМИ УСТРОЙСТВАМИ НА ОСНОВЕ ПРИНЦИПОВ РАБОТЫ СИНХРОННОГО ИЛИ АСИНХРОННОГО ИНТЕРФЕЙСОВ «МОЗГ-КОМПЬЮТЕР»

Д.В. Журавлёв¹, А.Н. Голубинский², А.А. Резниченко¹

¹Воронежский государственный технический университет
394006, Воронеж, ул. 20-летия Октября, д. 84

²Институт проблем передачи информации им. А.А. Харкевича РАН
127051, Москва, Большой Каретный переулок, д. 19 стр. 1

Статья поступила в редакцию 8 ноября 2024 г.

Аннотация. В статье рассматриваются вопросы исследований и разработки основных модулей программно-аппаратного комплекса управления роботизированными устройствами посредством биоэлектрических сигналов головного мозга. Целью работы является разработка теоретических и практических основ реализации универсального программно-аппаратного комплекса управления роботизированными устройствами на основе интерфейсов «мозг-компьютер». Разработанный комплекс позволяет организовать его работу как на основе синхронного, так и асинхронного типов интерфейсов. В этом заключается универсальность комплекса. В статье приведены основные отличия асинхронных интерфейсов «мозг-компьютер» от синхронных. Для того чтобы осуществить корректную работу классификатора были разработаны и апробированы методики предварительной обработки данных для обоих случаев как для использования синхронного, так и асинхронного интерфейсов «мозг-компьютер». Разработана единая архитектура

классификатора данных на основе модели многослойного персептрона, подходящая как для классификации волн P300 (при использовании синхронных интерфейсов), так и воображаемых движений (при использовании асинхронных интерфейсов). Проведена апробация системы, реализующая использование синхронного интерфейса «мозг-компьютер» в режиме онлайн. Средняя точность распознавания волн P300 составила 60% при циклическом повторении зрительных стимулов в непрерывном режиме работы системы. Также была проведена апробация системы, реализующая использование асинхронного интерфейса «мозг-компьютер», основанная на классификации моторных образов (воображаемых движений левой и правой рук). Средняя точность классификации в режиме онлайн составила 65%. Эффективность и актуальность интерфейсов «мозг-компьютер» асинхронного типа была подтверждена возможностью формировать управляющие сигналы на роботизированное устройство с помощью мысленных воображаемых движений оператора со средней точностью не ниже 65%. Причем система показала работоспособность с любым оператором без предварительной его тренировки. Это показывает целесообразность развития технологии неинвазивных интерфейсов «мозг-компьютер».

Ключевые слова: интерфейс «мозг-компьютер», волна P300, синхронный интерфейс, асинхронный интерфейс, классификация, моторные образы, программно-аппаратный комплекс.

Финансирование: Исследование выполнено за счет гранта Российского научного фонда № 24-29-20168, <https://rscf.ru/project/24-29-20168/>

Автор для переписки: Журавлёв Дмитрий Владимирович, ddom1@yandex.ru

Введение

Интерфейс «мозг-компьютер» (ИМК) – это система для обмена информации между головным мозгом человека и электронно-вычислительным устройством (ЭВМ). Предпосылками для начала развития ИМК можно считать 1924 год, когда ученый Ханс Боргер первым совершил открытие

электрической активности головного мозга, посредством записи сигналов электроэнцефалограммы (ЭЭГ). Первым ИМК-устройством можно считать Stimoseiver, протестированное на быке. С помощью этого устройства ученый Хосе Дельгадо смог заставить быка изменить направление движения. С тех пор, многие ученые начали проводить исследования в области разработки ИМК, совершенствовать их, находить для ИМК все большие прикладные применения в разных сферах деятельности человека. Так как применение технологии ИМК в различных областях и сферах деятельности открывает новые перспективы организации связи человека и ЭВМ на принципиально новом уровне [1], то в настоящее время исследования в данной области весьма актуальны.

Цель данной работы заключалась в разработке универсального программно-аппаратного комплекса (ПАК) для управления любыми робототехническими устройствами как с применением принципов синхронных, так и асинхронных ИМК. Для достижения поставленной цели были решены следующие задачи:

- с использованием материалов открытого источника OpenBCI (<https://openbci.com/>) был собран макет нейрокомпьютерного интерфейса; собранные и доработанные под наши задачи макеты печатных плат Cyton, Daisy и Wi-Fi модуля послужили основой устройства регистрации ЭЭГ для ИМК как синхронного, так и асинхронного типов;
- на языке высокого уровня Python было разработано комплексное программное обеспечение (ПО), позволяющее проводить полную обработку полученных сигналов (предобработку, классификацию), формирование стимульных воздействий и управляющих сигналов для роботизированного устройства; так же была разработана архитектура классификатора и сконфигурирована нейронная сеть для обработки данных ЭЭГ;
- проведена апробация разработанного ПАК как на сторонней базе записей ЭЭГ, так и на собственной базе в режимах офлайн и онлайн.

Разработанный универсальный ПАК показал свою эффективность в управлении роботизированными устройствами не стандартными методами без использования рук и ног.

1. Обзор материалов предшествующих работ

Потенциально ИМК при соответствующей доработке технологии могут быть внедрены в различные сферы деятельности человека. В связи этим экспоненциально растет количество исследований по данной тематике. Как отечественные, так и иностранные ученые исследуют различные типы ИМК, методы обработки данных, области применения и т.д.

В работах [2] и [3] рассматриваются инвазивные типы ИМК. Принцип работы таких ИМК заключается в имплантации датчиков для записи сигналов ЭЭГ под кожу головы. Поскольку для работы с такими типами ИМК требуется непосредственное хирургическое вмешательство в кору головного мозга человека, их использование весьма проблематично.

В настоящее время, довольно перспективным направлением является развитие неинвазивных ИМК [4]. Такие типы ИМК не требуют хирургического вмешательства в кору головного мозга. Электроды для записи сигналов ЭЭГ располагаются на поверхности головы человека. Поэтому, данный тип ИМК более доступен для широкого класса исследователей и пользователей. Довольно широкое распространение получили исследования ИМК на основе регистрации биоэлектрической активности головного мозга человека (ЭЭГ). Например, в работе [5] авторами применяется синхронный ИМК для исследования мультифрактальной суммарной биоэлектрической активности головного мозга. Так же нейроинтерфейсы применяются для выявления паттернов сигналов ЭЭГ, содержащих вызванные потенциалы, таких как волна P300 [6].

Работа ПАК на основе ИМК включает в себя следующие этапы: получение данных, предварительная обработка, извлечение признаков, классификация [7]. Этап получения данных заключается в осуществлении сеанса записи сигналов ЭЭГ. Предварительная обработка заключается в устранении помех, артефактов,

возникших во время сеанса записи сигналов ЭЭГ, а также различные преобразования сигналов для обеспечения нормальной работы классификатора. На начальном этапе предобработки сигналов широкое применение нашел общий пространственный фильтр (CSP). Так, например, в работе [8] авторы рассматривают метод CSP для предварительной обработки воображаемых движений. Так же, для предварительной обработки данных ЭЭГ широко используются методы главных компонент и независимых компонент. Извлечение признаков заключается в идентификации определенных характеристик сигнала ЭЭГ среди общего необработанного сигнала. Такими признаками могут быть потенциалы, связанные с событием, или волна P300, при работе в качестве синхронного ИМК, либо частотно-временные изменения сигналов, связанные с воображаемыми моторными образами, при работе в качестве асинхронного ИМК.

Классификаторы данных строят с использованием различных математических моделей, способов и методов, таких как линейный дискриминантный анализ (LDA), метод опорных векторов (SVM), а также классификаторы на основе искусственных нейронных сетей (ИНС), например многослойный персептрон (MLP) [9]. В работе [10] представлен обзор моделей и методов программной реализации ИНС. В рамках данной работы для классификации данных был использован MLP.

Весьма актуальным является внедрение ИМК для управления экзоскелетами, протезами, роботами и т.д. Так, например, в работе [11] представлено применение инвазивного синхронного ИМК для управления экзоскелетом кисти руки, а в работе [12] представлено применение неинвазивного асинхронного ИМК моторно-воображаемого типа для управления роботизированным экзоскелетом.

Таким образом, можно отметить следующее. ИМК неинвазивного типа в зависимости от метода обработки данных бывают двух видов: синхронные и асинхронные.

Принцип работы синхронных ИМК основан на выделении паттернов в сигналах ЭЭГ, содержащих отклики (вызванные потенциалы мозга), автоматически формируемые мозгом в ответ на предъявляемые человеку стимульные воздействия (визуальные, звуковые, тактильные воздействия и др.). В нашем случае ИМК синхронного типа включает в себя анализ временных интервалов вызванных потенциалов головного мозга, таких как волна P300 [13]. ИМК выполняет связующую функцию, а пользователь путем концентрации внимания определяет, какой раздражитель является ключевым для возникновения отклика в его мозговой активности. Классификатор в данном случае определяет среди всех данных ЭЭГ сигналов участки, имеющие характерные признаки амплитудных откликов мозговой активности. Эти участки и являются ответом на стимулирующее воздействие. Фактически данные ИМК служат просто для передачи внешних команд на управляющие устройства через центральную нервную систему человека, без преднамеренного и осмысленного участия самого человека в процессе передачи. Для каждого синхронного ИМК обязательно требуется длительное индивидуальное обучение оператора [7,14].

Асинхронный ИМК воспринимает произвольную активность головного мозга пользователя на протяжении всего времени работы. В нашем случае информация, поступающая от головного мозга, непрерывно анализируется и классифицируется в режиме реального времени. При этом оператор по своему желанию самопроизвольно может формировать управляющие воздействия [7]. Другими словами, асинхронные ИМК осуществляют более естественное взаимодействие человек – устройство, в отличие от синхронных. Однако работа асинхронных ИМК требует значительных вычислительных мощностей для обработки сигнала, реализации более совершенных математических моделей алгоритмов предобработки данных, а также способов формирования вторичных параметров на основе сигналов ЭЭГ. Асинхронные ИМК работающие на принципе выделения и анализа изменений частотных составляющих ЭЭГ сигналов в зависимости психоэмоционального состояния человека выделяют в отдельный подвид. Данные ИМК не находят широкого

применения еще более трудного процесса обучения оператора для того, чтобы достичь достоверности классификации управляющих воздействий хотя-бы 60-70% и малой повторяемости результатов классификаций.

Новизна предложенной разработки заключается в возможности работы ПАК, как в качестве синхронного, так и в качестве асинхронного ИМК.

2. Аппаратная реализация ИМК

Аппаратная реализация ИМК состоит из следующих составных частей:

- пластиковый шлем-держатель (нейрошлем) для ввинчивающихся электродов различного исполнения;
- основная плата регистрации (Cyton), осуществляющая регистрацию 8-ми каналов ЭЭГ монополярным способом или 4-х дифференциальных каналов биполярным способом;
- плата расширения (Daisy), осуществляющая регистрацию дополнительных 8-ми каналов ЭЭГ монополярным способом или 4-х дифференциальных каналов биполярным способом;
- плата радиоканала стандарта Wi-Fi для осуществления беспроводной передачи регистрируемых данных на ЭВМ;
- разработанное ПО для обработки данных и формирования управляющих воздействий.

Внешний вид собранных плат регистрации показан на рис. 1.




Рис. 1. Внешний вид аппаратуры регистрации ЭЭГ.

Плата Cyton является основной платой устройства регистрации. Она оснащена микроконтроллером PIC32. Так же плата включает в себя 8-ми канальную микросхему аналого-цифровых преобразователей (АЦП) ADS 1299 с разрешением 24 бита и возможной частотой дискретизации до 16 кГц.

Для обеспечения реализации 16-ти канального исполнения устройства служит плата расширения Daisy, позволяющая легко (без замены внутреннего программного обеспечения платы Cyton) нарастить количество каналов регистрации ЭЭГ до 16.

Для осуществления беспроводной связи с ЭВМ используется плата Wi-Fi. Электроды и устройство регистрации с аккумуляторной батареей были расположены на каркасе жесткой нейрогарнитуры распечатанной на 3D принтере. Датчики ЭЭГ применялись на основе «сухих» электродов без нанесения на них электропроводного геля. Варианты реализации изготовленного макета могут применяться в восьми или шестнадцатиканальных исполнениях. Универсальность аппаратного решения заключается в том, что на его основе можно оперативно формировать различные варианты построения регистрирующих устройств и реализации схем наложения электродов для съема информации.

В макете были использованы самодельные так называемые «штырьковые» электроды «сухого» типа на основе двухрядной вилки PLD, ножки которой изготовлены из латуни с напылением золота (рис. 2). Референтный электрод и электрод помехоподавления были подключены к ушам (к левому и правому соответственно). Собранный аппарат регистрации ЭЭГ имеет технические характеристики не хуже выпускаемых в настоящее время профессиональных регистраторов ЭЭГ медицинского назначения. Аппаратура имеет следующие основные технические характеристики: полоса пропускания 0,01-80 Гц; частота дискретизации 250-1000 Гц; входной импеданс усилителей 1 Гом; коэффициент усиления 1-24; внутренние шумы усилителей 0,35 мкВ; АЦП имеет разрядность 24 Бит; питание двухполюсное $\pm 2,5$ В.




Рис. 2. Пластиковый шлем-держатель с ввинчивающимися электродами «штырькового» типа.

Основной особенностью аппаратной реализации ИМК является возможность легкой установки и комбинации различных отведений электродов, количества каналов, коэффициентов усиления каждого канала, а также перенастройки ИМК под разные задачи использования. На рис. 3 представлен общий вид ЭЭГ гарнитуры.




Рис. 3. Общий вид ЭЭГ гарнитуры для реализации ИМК.

3. Программная реализация ИМК и общая структура ПАК

Программная реализация ИМК была осуществлена на языке Python. В общей сложности разработанный комплекс программных средств включает в себя 7 различных модулей:

- 1) модуль приема ЭЭГ сигналов;
- 2) модуль предобработки данных при реализации синхронного ИМК;
- 3) модуль предобработки данных при реализации асинхронного ИМК;
- 4) модуль классификации данных;
- 5) модуль формирования управляющих сигналов на роботизированное устройство;
- 6) модуль предъявления зрительных символов;
- 7) модуль осуществления взаимодействия виртуального пульта управления, классификатора и остальных модулей.

Так же разработанное ПО позволяет проводить визуализацию и сохранение регистрируемых данных в файлы для последующей обработки в режиме офлайн или для передачи данных в другие программы для анализа, такие как, например, MathLAB [15].

Для классификации данных ЭЭГ в ПО применялась ИНС. Для того чтобы разработать оптимальные методики предобработки сигналов, а также архитектуру классификатора требуется большой набор ЭЭГ данных, собранных с различных испытуемых. Причем ЭЭГ сигналы должны гарантированно исключать различные артефакты, которые могут возникнуть при регистрации ЭЭГ при помощи «сухих» электродов с использованием собранной аппаратуры регистрации. Такой «чистый» набор записей ЭЭГ может быть получен в специальных лабораторных условиях при использовании традиционной аппаратуры регистрации ЭЭГ с применением стандартных «мокрых» электродов. Поэтому для того, чтобы провести разработку архитектуры классификатора, методики предобработки данных, провести предварительное тестирование и апробацию разработанного ПАК была использована сторонняя база записей ЭЭГ сигналов, взятая из открытого источника (<https://mne.tools/>).

Данная база данных содержит многочисленные записи ЭЭГ сигналов с различных испытуемых, сделанных в центре биомедицинской визуализации имени Атинулы А. Мартиноса, который является частью отделения радиологии Массачусетской больницы общего профиля. Данный центр плотно взаимодействует с Гарвардским университетом и Массачусетским технологическим институтом. Записи проводились на 60-ти канальной профессиональной аппаратуре Neuromag Vectorview с применением технологии «мокрых» электродов.

При проведении регистрации ЭЭГ сигналов испытуемым предъявлялись различные стимульные воздействия каждые 750 мс. Факты начала и конца предъявления стимулов, а также информация о виде воздействия записывались вместе с сигналами в файлы с привязкой к ЭЭГ по времени. В табл. 1 представлены коды и описания стимулирующих воздействий при проведении измерений.

Таблица 1. Виды стимульных воздействий.

Имя стимула	Номер стимула	Описание
LA	1	Реакция на слуховой стимул левого уха
RA	2	Реакция на слуховой стимул правого уха
LV	3	Реакция на стимул левого поля зрения
RV	4	Реакция на стимул правого поля зрения
Смайлик	5	Ответ на смайлик
Кнопка	32	Реакция на нажатие кнопки

Для того чтобы определить наличие или отсутствие волн P300 в ЭЭГ сигналах, достаточно всего 8-ми каналов из возможных 60-ти. Наиболее информативными являются каналы: 047, 048, 049, 054, 055, 057, 058, 059 (локализацию данных электродов можно посмотреть на сайте проекта <https://mne.tools/>). Кроме того, при использовании только 8-ми каналов становится возможным провести обучение ИНС на пользовательской ЭВМ.

Для корректной работы классификатора на основе ИНС необходимо сначала осуществить предобработку данных. Разработанная методика предобработки данных заключается в следующем. Сначала было проведено формирование эпох (кусков данных), содержащих участки с волной P300. Для этого была проведена нарезка данных с длиной участка ЭЭГ сигнала

с началами за 0,5 сек. до начала предъявления стимула и окончаниями через 1 сек. после предъявления.

В массив «epochs» записывались участки (эпохи) от $-0,5$ до $+1$ относительно события №5 с волной P300 (участнику представлен смайлик) для выбранных 8-ми каналов ЭЭГ. Так как в записях событие №5 встречается 12 раз, то соответственно мы создаем 3-х мерный массив с 12-ю двухмерными массивами для каждого события. Каждое событие включает в себя по 8 каналов. Всего должно быть $12 \times 8 = 96$ эпох (одномерных массивов). Эти одномерные массивы находятся в 3-х мерном массиве «epochs» вида:

```
[
1-е событие № 5 [[эпоха для канала 47], ..., [эпоха для канала 59]],
2-е событие № 5 [[эпоха для канала 47], ..., [эпоха для канала 59]],
...
12-е событие № 5 [[эпоха для канала 47], ..., [эпоха для канала 59]]
]
```

В массив «epochsNoP300» были записаны участки (эпохи) от $-0,5$ до $+1$ относительно событий № 1,2,3,4. Получилось всего 208 событий с номерами 1,2,3,4 (все эти события не содержат волны P300). Всего мы имеем $208 \times 8 = 1664$ эпох. При этом 3-х мерный массив «epochsNoP300» был приведен к виду:

```
[
1-е событие (1-4) [[эпоха для канала 47], ..., [эпоха для канала 59]],
2-е событие (1-4) [[эпоха для канала 47], ..., [эпоха для канала 59]],
...
60-е событие (1-4) [[эпоха для канала 47], ..., [эпоха для канала 59]]
]
```

Далее в случае необходимости 3-х мерный массив «epochs» преобразовывался в 2-х мерный с помощью функции «pr.squeeze».

Затем были созданы два единых вектора входных данных для эпох с P300 и без них. Для этого эпохи с P300 для всех каналов заносились в ячейки одной строки массива. Размерность массива составляла 12 строк (соответствующих 12-ти событиям №5) и 1808 столбцов (соответствующих каждому отсчету каждой эпохи для всех 8 каналов). В результате было получено, что каждая эпоха

имеет $1808 / 8 = 226$ отсчетов (элементов массива). Результирующий двумерный массив «p300s» имел следующий вид:

```
[
1-е событие № 5 [эпохи для всех 8 каналов], ..., [эпохи для всех 8 каналов],
2-е событие № 5 [эпохи для всех 8 каналов], ..., [эпохи для всех 8 каналов],
...
12-е событие № 5 [эпохи для всех 8 каналов], ..., [эпохи для всех 8 каналов]
]
```

Аналогичные операции были проведены для данных, не содержащих волны P300. Затем было проведено транспонирование (замена строк и столбцов местами) для обоих входных векторов. После проведения операции в случае с массивом «p300s», он стал представлять собой массив вида:

```
[
1-й отсчет в эпохах [1-е событие № 5], ..., [12-е событие № 5],
1-й отсчет в эпохах [1-е событие № 5], ..., [12-е событие № 5],
...
1808-й отсчет в эпохах [1-е событие № 5], ..., [12-е событие № 5]
]
```

Многие алгоритмы машинного обучения (в нашем случае ИНС) работают лучше или сходятся быстрее, когда признаки примерно одинакового масштаба и нормально или почти нормально распределены. Масштабирование проводится для того, чтобы избежать влияния максимальных и минимальных выбросов сигналов. Поэтому следующая операция методики предобработки представляла собой выполнение нормализации данных (для обоих входных векторов) с помощью функции `RobustScaler()`. После выполнения нормализации было выполнено обратное транспонирование массивов к виду, где строки соответствуют событиям. Далее оба вектора были разделены на обучающие и проверочные выборки.

Для того чтобы сконфигурировать нейронную сеть был использован пакет программ «Keras», который, в свою очередь, содержит алгоритм машинного обучения «Dropout» и позволяет его применять к любому слою нейронной сети так, чтобы не допустить переобучение и сокращение числа нейронов [16].

Исходя из приведенных выше рассуждений эффективность применения ИНС для классификации данных следует проверять при использовании нейронной сети с 1808 входными нейронами, так как данные представляют собой наборы по 226 элементов для каждого из 8-ми каналов ($226 \times 8 = 1808$). Наличие скрытых слоев и их количество определялось экспериментальным путем. Лучшие результаты в нашей задаче бинарной классификации показала ИНС, имеющая два скрытых слоя по 128 нейронов в каждом. Для активации нейронов в скрытых слоях нами была использована кусочно-линейная функция ReLU.

Для измерения эффективности модели классификации была использована бинарная кросс-энтропия:

$$E = -\frac{1}{N} \sum_{i=1}^N [d_i \log y_i + (1-d_i) \log (1-y_i)] \quad (1)$$

Выходные значения функции ошибки (бинарной кросс-энтропии) представляют собой вероятностные значения между 0 и 1: $d_i \in \{0,1\}$.

Для нормирования данных была использована функция Softmax, которая превращает логиты (наборы чисел) в вероятности и выводит их в виде выходного вектора распределения вероятностей результатов. Значения Z_k на выходе ИНС были преобразованы в вероятности принадлежности к одному из 2-х классов:

$$y_1 = \frac{e^{z_1}}{e^{z_1} + e^{z_2}}; \quad y_2 = \frac{e^{z_2}}{e^{z_1} + e^{z_2}}. \quad (2)$$

Разработанная ИНС была обучена для успешной классификации эпох, связанных с реакцией на показ смайлика (стимул №5). Для наглядного представления о качестве работы нейронной сети были рассчитаны и построены критерии качества работы сети, которые представляют собой обучающее и проверочное множество. Обучающее множество – это набор данных, в котором определены ожидаемые от ИНС результаты. Проверочное множество обеспечивает беспристрастную оценку соответствия модели набору данных обучения при настройке её гиперпараметров. Для того чтобы определить

эффективность работы ИНС представим график (рис. 4) изменения функций ошибок от эпох обучения. Эпохи обучения были ограничены количеством 50. При этом в качестве оптимизатора использовался оптимизатор ADAM. Оптимизатор ADAM представляет собой алгоритм метода оптимизации для градиентного спуска, разработанный на основе обычного стохастического градиентного спуска.




Рис. 4. Зависимость изменения функций ошибок для обучающего и проверочного множеств от числа эпох обучения.

Анализируя график для проверочного множества, можно увидеть следующее: построенная нейронная сеть на протяжении первых десяти эпох обучается, далее значение функции ошибки падает, остается неизменным и начинает плавно возрастать только примерно с 24-ой эпохи обучения. Следовательно, к 10-й эпохе наступает эффект переобучения, а после 24-й эпохи нейронная сеть полностью теряет свою способность к обобщению.

Для борьбы с переобучением нами был использован алгоритм «Dropout». Данный алгоритм показал свою эффективность. Основной особенностью алгоритма обучения «Dropout» является «отсев» определенного количества

нейронов сети. Вероятность исключения нейрона из сети k определяется с помощью выражения $k = 1 - m$, где m это вероятность того, что нейрон останется в сети. Используя отсев нейронов, появляется возможность на каждой итерации работать с нейронной сетью, меньшей по размеру, чем предыдущая. Следовательно, она приближается к регуляризации. Так же отсев нейронов позволяет уменьшить квадратическую норму весов, что тоже уменьшает эффект переобучения. На рис. 5 представлен отсев части нейронов.




Рис. 5. «Отсев» нейронов из сети.

После того, как обучение нейронной сети завершено, активируются все, отключенные ранее, нейроны. После проведенных манипуляций, эффект переобучения снижается. В результате операции отсева в процессе обучения ИНС с вероятностью P происходит уменьшение входного веса каждого нейрона. Пример ИНС с нейронами f_1 и f_2 отсеянными в процессе обучения представлен на рис. 6.




Рис. 6. ИНС с нейронами f_1 и f_2 отсеянными в процессе обучения.

При этом числовое значение сигнала на входе нейрона во время теста представляет собой значение x , а во время обучения $x_q < x$. Отсев нейронов приводит к тому, что во входном сигнале появляются искажения и, следовательно, нейронная сеть выдает неверный выходной сигнал.

Для борьбы с искажениями сигнала, принято рассчитывать общее число отсеиваемых нейронов в рассматриваемом слое нейронной сети. Число таких нейронов равно N . Сначала целесообразно провести расчет математического ожидания по формуле:

$$D(N) = \sum_{i=1}^m N_i \cdot P_i, \quad (3)$$

где N – общее число отсеиваемых нейронов (случайная величина); N_i – количество нейронов в слое, к которому применима вероятность отсеивания (в нашем случае $N_i = 1$); P_i – вероятность отсеивания нейронов в слое.

Далее, принимая во внимание вышесказанное, математическое ожидание можно преобразовать к следующему виду:

$$D(N) = \sum_{i=1}^m P = m \cdot P. \quad (4)$$

Общее количество оставленных нейронов для каждого слоя можно определить по формуле:

$$m - m \cdot P = m \cdot (1 - P) = m \cdot P, \quad (5)$$

где P – вероятность того, что нейрон не будет отсеян.

Среднее суммарное значение входного сигнала для следующего слоя нейронов определяется как:

$$\frac{N_q}{N} \approx \frac{mq}{m} = q. \quad (6)$$

Общее число отсеиваемых нейронов N при этом можно определить, если разделить выражение (6) на q , в результате этого сохраним масштаб суммы и получим:

$$N_q \cdot \frac{1}{q} \approx N. \quad (7)$$

Таким образом, в результате применения алгоритма «Dropout» реализованного описанным способом удастся получить выходной сигнал ИНС с минимальными искажениями. В общем случае значение вероятности отсеивания нейронов принимают $P = 0,5$. Однако для каждого скрытого слоя данный параметр следует рассчитывать индивидуально. В нашем случае параметр P был определен экспериментально и составил 0,3.

В разработанной нейронной сети, число нейронов скрытых слоев составило 128. В результате, при использовании модуля «Keras» был применен алгоритм «Dropout» с вероятностью $P = 0,3$. Форма изменения функции ошибки для обучающего и проверочного множеств при использовании в процессе обучения алгоритма «Dropout» представлена на рис. 7

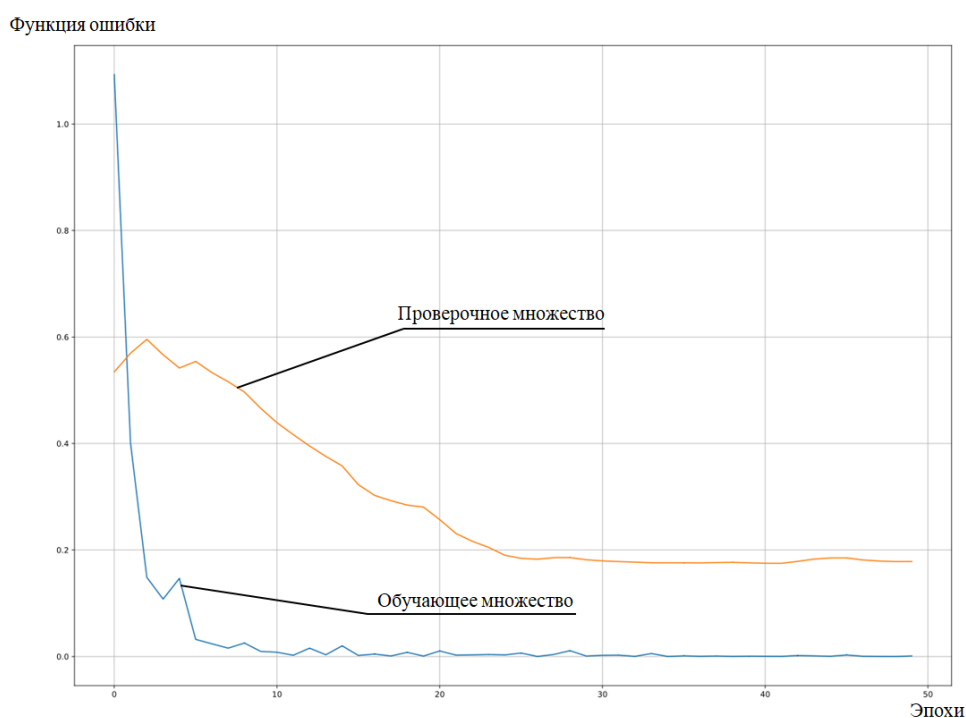


Рис. 7. Формы изменений функций ошибки работы ИНС, с использованием алгоритма «Dropout»

Анализируя представленные графики, можно сделать вывод о том, что функция ошибки для проверочного множества достигает своего минимума к 40-ой эпохе, в то время как без использования алгоритма «Dropout» (рис. 4) уже к 10-ой эпохе наблюдался эффект переобучения.

В результате проведенных исследований была разработана методика предобработки данных, а также структура ИНС, основанная на применении модели MLP. Разработанная модель содержит два скрытых слоя. Каждый слой имеет 128 нейронов. Для активации нейронов была использована функция ReLU. Также был использован модифицированный оптимизатор на основе стохастического градиентного спуска под названием ADAM. Для борьбы с переобучением нами использовался алгоритм «Dropout» («метод исключения»).

Для того чтобы реализовать интерфейс управления робототехническим устройством был разработан модуль ПО, обеспечивающий предъявление зрительных стимулов на экране ПК. Для удобства предъявления всего доступного набора команд по управлению роботом был разработан пульт управления. Пульт содержит кнопки с интуитивно понятными обозначениями: движение вперед, назад, влево, вправо, на малой, средней или большой скоростях. Разработанное ПО в случайном циклическом порядке подсвечивает каждую кнопку путем увеличения её яркости на время равное 0,5 сек. Оператору остается только сконцентрироваться на выбранной кнопке для генерации его мозгом волны P300.

Для управления роботом используются сразу 3 модуля разработанного ПО: модуль предъявления зрительных символов, модуль организации виртуального пульта управления роботом погрузчиком и модуль формирования управляющих сигналов. Интерфейс разработанного ПО позволяет установить цвет подсветки каждой кнопки, цвет самой кнопки без подсветки, а также время подсветки кнопки. Функция «timer» позволяет осуществить в случайном порядке подсветку кнопок. В том случае, если нейронная сеть распознает когнитивную волну P300, генерируется событие, которое вызывает обработчик «battselect».

Общая структурная схема разработанного ПАК представлена на рис.8. Оператор имеет возможность выбирать, какой режим работы ПАК будет использован: режим с ИМК синхронного или асинхронного типа. При организации работы с использованием ИМК синхронного типа модуль предъявления стимулов, включающий в себя разработанный виртуальный пульт управления, оказывает зрительные стимульные воздействия на оператора.

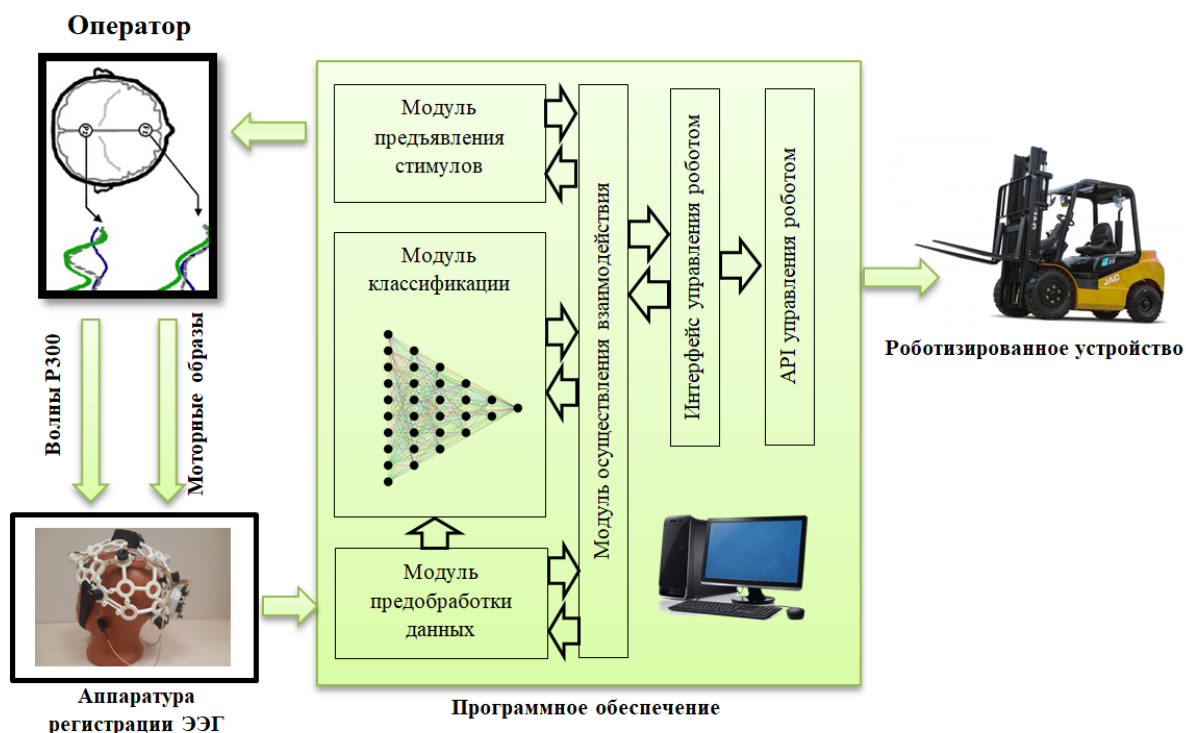


Рис. 8. Структурная схема разработанного ПАК.

Путем определенной концентрации на необходимой кнопке мозг оператора формирует волну Р300, являющуюся откликом на событие яркого подсвечивания данной кнопки. Программное обеспечение, используя построенный классификатор (на основе модели MLP), определяет факт возникновения волны Р300 возникшей после предъявления стимула. Возникновение волны Р300 следом за подсвечиванием конкретной кнопки на пульте управления означает, что оператор хочет направить на роботизированное устройство именно команду, привязанную к данной кнопке. Используя интерфейс управления роботом, программа через интерфейс программирования приложений (API) направляет соответствующие команды управления.

При выборе режима с использованием асинхронного ИМК оператору не нужен пульт управления и модуль предъявления стимулов. Оператор мысленно представляет моторные образы (в нашем случае мысленное движение левой или правой рукой), система классифицирует эти образы и с определенной долей вероятности формирует команду на движение роботизированного устройства влево или вправо.

В разработанном и реализованном ИМК синхронного типа общее число команд, необходимых для управления роботом и доступных оператору представлено в виде виртуального пульта управления, который разработан в графическом редакторе. Сначала, в графическом редакторе было создано рабочее окно программы. Цветное изображение имеет 256 цветов. Каждый пиксель изображения содержит индекс цвета. Цвета кнопок индексированного изображения были записаны следующим образом: первая кнопка $R = 0, G = 0, B = 0$; вторая кнопка $R = 1, G = 1, B = 1$; остальные в таком же порядке. На рис. 9 представлен макет пульта управления роботизированным устройством, разработанный в графическом редакторе.

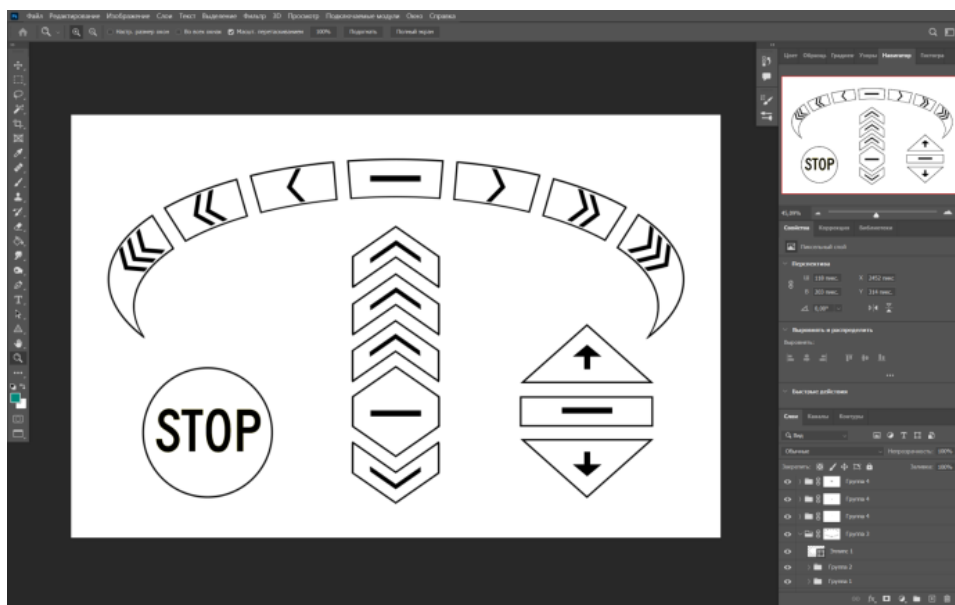


Рис. 9. Макет пульта управления.

Макет включает в себя набор кнопок для управления: движение вперед на малой, средней и большой скорости, движение назад на малой скорости, так же есть малый, средний или большой поворот налево или направо.

Кнопка «stop» отвечает за остановку погрузчика. Конечный вариант пульта управления роботом представлен на рис. 10.



Рис. 10. Готовый пульт управления роботом-погрузчиком.

На рис. 10 мы видим, что кнопка движения вперед на средней скорости находится в активном (подсвеченном) состоянии. Так же в активном состоянии находится кнопка минимального поворота направо.

В программный модуль «actionBatt» можно записать функции реакции на кнопки управления. Обработчик срабатывает на включение кнопки только тогда, когда результат классификации волн P300 имеет точность классификации более 60%. Обработчик выключается в том случае, если точность классификации менее 60%. Функции обработчиков нажатия кнопок сохраняются в файле «actionBatt.py» для каждого робота персонально.

4. Апробация ПАК и обсуждение результатов

Рассмотренные наработки, как в аппаратной, так и программной частях позволили создать законченный ПАК имеющий возможность осуществлять управление, роботизированным устройством используя принципы работы синхронного или асинхронного ИМК.

Для того чтобы разработать архитектуру классификатора, методику предобработки данных и провести предварительную апробацию принципов

работы синхронного ИМК была использована сторонняя открытая база данных ЭЭГ записей (<https://mne.tools/>). База данных широко известна и содержит записи 64-х каналов ЭЭГ от различных испытуемых. Во время осуществления записей испытуемым предъявляли стимульное воздействие в виде показа смайлика на экране монитора в случайные промежутки времени. Записи содержат информацию о времени начала и окончания предъявления стимулов. Для обработки были использованы всего 8 каналов ЭЭГ, в которых присутствие волн P300 наиболее заметно. Используя разработанную методику предобработки данных, было проведено формирование входного тензора данных содержащих участки ЭЭГ сигналов во время предъявления стимулов. Длина тензора составляла 1808 элементов. Такой набор данных служил обучающей выборкой для нейронной сети. Также был сформирован набор данных ЭЭГ такой же длины для 8-ми каналов, не содержащих участки сигналов с волнами P300. Далее была построена и обучена ИНС, решающая задачу распознавания наличия потенциала P300. Такая ИНС была основана на распространенной модели MLP. Экспериментально было определено, что для корректной работы модели достаточно двух скрытых слоев. Также было рассчитано, что каждый слой должен содержать по 128 нейронов. Определено, что активацию нейронов целесообразно проводить с помощью функции ReLU, а для определения корректности работы ИНС использовать бинарную кросс-энтропию. В качестве оптимизатора использовался оптимизатор ADAM представляющий собой модификацию стохастического градиентного спуска. Для борьбы с переобучением был использован алгоритм «Dropout» отдельно для каждого слоя. Разработанная модель ИНС успешно провела классификацию признаков.

Разработанное комплексное ПО помимо модуля обработки ЭЭГ данных и классификации включает в себя модуль предъявления стимулов в виде пульта управления роботизированным устройством. Таким образом, был построен интерфейс взаимодействия оператора с роботом, разработан и обучен классификатор на основе MLP.

Апробация ПАК в качестве синхронного ИМК была проведена в режиме онлайн при использовании рассмотренной выше аппаратуры регистрации ЭЭГ. Предъявляемые пультом управления зрительные стимулы успешно классифицировались в онлайн режиме со средней точностью до 60%. В результате классификации ПО формировало управляющие команды, которые можно использовать для управления роботизированным устройством.

Апробация разработанного ПАК в качестве асинхронного ИМК проводилась только на собственной базе записей ЭЭГ данных. Собственная база записей была получена при использовании рассмотренной выше аппаратуры регистрации ЭЭГ. Регистрация и обработка данных проходила для 16-ти канального исполнения аппаратуры регистрации. Всего было сформировано около 50-ти сессий измерений для разных испытуемых. Для того чтобы провести обучение классификатора был проведен ряд сеансов записей, во время которых оператор старался формировать четкие моторные образы. Чтобы оператор знал, когда именно начинать, а когда заканчивать мысленное действие программа формировала стрелки-подсказки (влево/вправо) на экране ЭВМ, появляющиеся на определенное время.

Методика предобработки данных как для режима офлайн, так и для режима онлайн заключалась в следующем. Сначала данные ЭЭГ подвергались полосовой фильтрации. Затем блок «Switch director» осуществлял разбиение ЭЭГ сигнала на участки длительностью по 4 сек. со смещением 0,5 сек. Далее сигнал пропусклся через блок пространственной фильтрации CSP. Далее все данные объединялись в один вектор и поступали на блок «Time based epoching», который разбивал вектор на блоки (генерировал срезы сигнала), имеющие длительность 1 сек. и следующие друг за другом с интервалом 0.0625 сек. Далее происходила обработка сигналов в метаблоке «Signal Power Log»: возведение каждого отсчета входного вектора в квадрат; вычисление среднего значения всей выборки; выполнение уравнения $y = \log(1 + x)$. После этого все фрагменты объединялись в единый вектор признаков в блоке «Feature aggregator». Такой вектор подавался на вход блока классификации «Classifier processor».

Архитектура классификатора была выбрана такой же, как и в случае использования синхронного ИМК, описанного выше.

Сначала было проведено обучение классификатора на обучающей выборке. Для формирования проверочной выборки проводились записи также 16-ти каналов ЭЭГ данных. Выполнялись сеансы записей, длительностью по 7 мин 10 сек. Во время сеансов оператор периодически осуществлял мыслительные действия в виде движений левой или правой рукой. Для каждого сеанса записи количество мыслительных образов составляло 40 штук (20 для левой руки и 20 для правой) в случайном порядке. Продолжительность каждого мыслительного образа составляла 2 сек. Для того чтобы оператор знал когда начинать мысленные движения, когда заканчивать, движения какой руки (левой/правой) представлять, разработанное ПО в случайном порядке формировало на экране монитора подсказки в виде стрелок (влево/вправо). Длительность показа стрелок соответствовала желаемой длительности мыслительного образа.

После обучения классификатора в офлайн режиме был проведен ряд экспериментов по классификации моторных образов в режиме онлайн. Оператор проводил формирование моторных образов, соответствующих движениям левой или правой руки в произвольном порядке в случайные промежутки времени. Разработанный классификатор на основе модели MLP проводил классификацию в режиме онлайн, программа формировала управляющие сигналы (влево/вправо) для роботизированного устройства.

Максимальная средняя для 10-ти сеансов точность классификации при использовании ПАК в качестве асинхронного ИМК в режиме онлайн составила 65%.

Заключение

В работе были описаны основные этапы разработки универсального ПАК, позволяющего реализовать управление роботизированным устройством как на основе принципов работы синхронных, так и асинхронных ИМК.

Следует отметить, что ИМК, основанный на обработке сигналов ЭЭГ, позволяет скрытно и эффективно управлять роботизированным устройством без использования рук и ног человека.

Универсальность разработанного комплекса заключается в том, что модули аппаратной и программной реализации ИМК, в том числе и модуль классификации данных (классификатор, построенный с использованием модели MLP), могут использоваться как при организации работы синхронного, так и асинхронного ИМК.

Учитывая, что ИМК асинхронного типа наиболее перспективны, данный ПАК позволяет вплотную подойти к реализации многоканального управления роботизированными устройствами при помощи асинхронных ИМК. Эффективность и актуальность ИМК асинхронного типа заключается в возможности формировать управляющие воздействия с помощью воображаемых движений, причем любым оператором без предварительной тренировки. Это открывает новые сферы практически повсеместного применения ИМК в различных отраслях науки и техники.

Финансирование: Исследование выполнено за счет гранта Российского научного фонда № 24-29-20168, <https://rscf.ru/project/24-29-20168/>

Литература

1. Журавлев Д.В. Аппаратура для электроэнцефалографических исследований. – 2021.
2. Schwartz A.B. Cortical neural prosthetics // *Annu. Rev. Neurosci.* – 2004. – Т. 27. – №. 1. – С. 487-507.
3. Homer M.L. et al. Sensors and decoding for intracortical brain computer interfaces // *Annual review of biomedical engineering.* – 2013. – Т. 15. – №. 1. – С. 383-405.
4. Станкевич Л.А. и др. Классификация электроэнцефалографических паттернов воображаемых движений пальцами руки для разработки интерфейса мозг-компьютер // *Информатика и автоматизация.* – 2015. – Т. 3. – №. 40. – С. 163-182.

5. Mayorov O.Y., Fenchenco V.N. Multifractal analysis in the study of brain bioelectric activity // *Zn. Kibernetika i vychislitel'naya tekhnika.* – С. 81-94.
6. Ганин И.П., Каплан А.Я. Изучение эффектов вариативности потенциалов мозга человека в интерфейсе мозг–компьютер на волне P300 // *Вестник Российского государственного медицинского университета.* – 2022. – №. 3. – С. 78-85.
7. Сысков А.М., Борисов В.И., Петренко Т.С. Проектирование мультимодальных интерфейсов мозг-компьютер: учебно-методическое пособие. – 2023.
8. Wetzel D. et al. Significance of EEG-electrode combinations while calculating filters with common spatial patterns // *GMS German Medical Science.* – 2024. – Т. 22. – С. Doc08.
9. Chakole A.R. et al. Review of EEG signal classification // *Information and Communication Technology for Intelligent Systems: Proceedings of ICTIS 2018, Volume 2.* – Springer Singapore, 2019. – С. 105-114.
10. Ловгонюк В.Н., Нусс Э.А. МОДЕЛИ И МЕТОДЫ АППАРАТНОЙ РЕАЛИЗАЦИИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ // *Science and technology innovations-2023.* – 2023. – С. 100-109.
11. Кондур А.А. и др. Восстановление двигательной функции руки после инсульта с помощью интерфейса “мозг-компьютер”, управляющего экзоскелетом кисти: эффект повторных госпитализаций // *Физиология человека.* – 2020. – Т. 46. – №. 3. – С. 99-110.
12. Gordleeva S.Y. et al. Exoskeleton control system based on motor-imaginary brain–computer interface // *Современные технологии в медицине.* – 2017. – Т. 9. – №. 3 (eng). – С. 31-36.
13. Журавлёв Д.В., Резниченко А.А. Интерфейс мозг-компьютер на волне P300 с использованием нейронных сетей // *Радиоэлектронная техника.* – 2022. – С. 142-151.
14. Roman-Gonzalez A. EEG signal processing for BCI applications // *Human–computer systems interaction: backgrounds and applications.* – 2012. – Т. 2. – С. 571-591.

15. Zhang W. et al. A review of EEG-based brain-computer interface systems design // Brain Science Advances. – 2018. – Т. 4. – №. 2. – С. 156-167.
16. Голубинский А.Н., Толстых А.А. О применении сверточных нейронных сетей для классификации моторики на основе сигналов ЭЭГ интерфейса мозг-компьютер // Наукосфера. – 2021. – №. 2-1. – С. 85-88.

Для цитирования:

Журавлёв Д.В., Голубинский А.Н., Резниченко А.А. Универсальный программно-аппаратный комплекс для управления роботизированными устройствами на основе принципов работы синхронного или асинхронного интерфейсов «мозг-компьютер». // Журнал радиоэлектроники. – 2025. – №. 1. <https://doi.org/10.30898/1684-1719.2025.1.1>