

DOI: <https://doi.org/10.30898/1684-1719.2025.11.34>

УДК: 004.032.26; 621.396

**ИССЛЕДОВАНИЕ БИНАРНЫХ КЛАССИФИКАТОРОВ,
БАЗИРУЮЩИХСЯ НА РАЗНЫХ МАТЕМАТИЧЕСКИХ ПОДХОДАХ
ПРИ РАСПОЗНАВАНИИ МОТОРНЫХ ОБРАЗОВ ДВИГАТЕЛЬНОЙ
АКТИВНОСТИ В ИНТЕРФЕЙСЕ «МОЗГ-КОМПЬЮТЕР»
АСИНХРОННОГО ТИПА**

Д.В. Журавлев¹, А.А. Резниченко¹, А.Н. Голубинский¹, А.А. Толстых²

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

² ООО «РТК», 107140, Москва, Верхняя Красносельская ул., 16с1

Статья поступила в редакцию 11 сентября 2025 г.

Аннотация. В настоящее время, предпринимается множество попыток создать интерфейс «мозг-компьютер» асинхронного типа, который мог бы осуществлять распознавание моторных образов с высокой точностью. Однако на практике добиться точности распознавания даже более чем 60 % в режиме «онлайн» является сложной задачей, особенно при использовании переносной регистрирующей аппаратуры. В данной работе предпринята попытка создания переносного малогабаритного интерфейса «мозг-компьютер» асинхронного типа, предназначенного для распознавания моторных образов в режиме реального времени с точностью бинарной классификации не менее 65 %. Для достижения поставленной цели был создан макет аппаратуры, передающий в режиме «онлайн» регистрируемые электроэнцефалографические сигналы на персональный компьютер по радиоканалу стандарта Wi-Fi. Автономный макет аппаратуры располагался на переносной нейрогарнитуре с резистивно-емкостными электродами «сухого» типа. В работе рассмотрены теоретические аспекты используемых подходов, представлена структурная схема

программной системы, реализующей распознавание, проанализированы результаты экспериментального применения предлагаемой системы. На языке Python разработано программное обеспечение, предназначенное для предобработки сигналов, выделения признаков и их классификации. В рамках работы было проведено исследование нескольких классификаторов, базирующихся на разных математических подходах: линейный дискриминантный анализ (LDA), многослойный персептрон, сверточная нейронная сеть, представляющая собой повторяющиеся части архитектуры, которые состоят из некоторого набора различных слоев (ResNet). Разработана архитектура сети, состоящей из восемнадцати слоев. Также были исследованы методы оптимизации первого и второго порядков. Оценка влияния алгоритмов оптимизации на работу нейросетевых классификаторов была проведена с использованием метрик Accuracy, Precision, Recall и F1 мера. Всего было исследовано четыре алгоритма оптимизации: алгоритм адаптивной оптимизации импульсов (ADAM), алгоритм Левенберга-Марквардта (LM), алгоритм стохастического градиентного спуска (SGD), алгоритм Бroyдена-Флетчера-Гольдфарба-Шанно (BFGS). Предложена модернизация алгоритма Левенберга-Марквардта применительно к задачам классификации моторных образов. Наивысшую точность классификации (метрика Accuracy) моторных образов удалось достичь при использовании классификатора на основе ResNet и алгоритма оптимизации ADAM. Точность классификации в режиме «офлайн» составила 68,31 % (метрика Accuracy) и 68,80 % (метрика Recall), в режиме «онлайн» 65,92 % и 66,20 % соответственно.

Ключевые слова: интерфейс «мозг-компьютер», моторные образы, градиентный спуск, алгоритм Левенберга-Марквардта, сверточная нейронная сеть, ResNet, линейный дискриминантный анализ, полносвязный персептрон, алгоритмом оптимизации BFGS

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

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

Введение

Одним из перспективных направлений в области взаимодействия человека с техническими системами является разработка интерфейсов «мозг-компьютер» (ИМК). Данное направление является мультидисциплинарным ввиду того, что помимо распознавания электроэнцефалографических (ЭЭГ) сигналов от человека (решения задачи классификации), необходимо решить задачи снятия сигналов с мозга человека (задачи разработки и конструирования приборов регистрации) и первичной обработки таких сигналов (математические задачи обработки и преобразования данных). Актуальность решения проблемы по созданию ИМК обусловлена необходимостью скрытно предавать информацию для управления различными робототехническими комплексами, системами, экзоскелетами и т.д. без использования рук, ног и дополнительных манипуляторов.

ИМК неинвазивного типа подразделяются на два вида по принципу выделения информативных составляющих из ЭЭГ сигналов.

Первый вид – это так называемые, синхронные ИМК [1]. Принцип работы таких 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.). 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. При этом для каждого ИМК и работающего с ним оператора требуется индивидуальное обучение, приводящее к значительному разбросу достоверности выделения управляющих сигналов у различных операторов. После обучения оператора точность распознавания команд в таких ИМК достаточно высока и достигает 95-97 %. Однако данные ИМК ограничены в применении из-за указанных недостатков.

Второй вид – это асинхронные ИМК. Такой вариант реализации не требует внешних стимулов и позволяет анализировать всю приходящую

электроэнцефалографическую информацию в режиме реального времени. При этом оператор может формировать различные осмысленные управляющие команды двумя способами: путем изменения своего психоэмоционального состояния (первый вид асинхронных ИМК, которые основаны на частотном анализе ЭЭГ [1]), либо путем мысленного представления воображаемых действий (второй вид асинхронных ИМК, которые основаны на нелинейном анализе и классификации сегментов многопараметрического временного ряда с применением классификаторов различного типа).

Основными проблемами реализации асинхронных ИМК первого вида являются значительная неповторимость и низкая достоверность классификаций (точность классификации порядка 60-70 % в режиме «онлайн») управляющих воздействий, которые связаны в первую очередь с тем, что даже натренированный оператор далеко не всегда может повторно сформировать свое внутреннее состояние, приводящее к изменению частотной области ЭЭГ сигнала.

В асинхронных ИМК второго вида оператор формирует различные осмысленные управляющие команды путем мысленного представления, например движений рук или ног. При этом долгого предварительного обучения оператора не требуется. Асинхронные ИМК работающие на принципе выделения и анализа паттернов ЭЭГ, связанных с воображаемыми движениями (MI, motor imagery), являются наиболее перспективными для исследований и разработок. Они могут быть использованы любым оператором без его предварительной тренировки. Однако технология создания ИМК еще недостаточно проработана.

Анализ научных публикаций по вопросам распознавания моторики (как воображаемой, так и реальной) с помощью классификации сигналов ЭЭГ показал, что при разработке ИМК наиболее перспективными являются методы, основанные на использовании аппарата сверточных нейронных сетей (СНС) с предварительной цифровой обработкой сигналов (ЦОС). В рамках данной работы приводится рассмотрение вопросов проектирования асинхронного ИМК

второго типа (включающего в себя как аппаратную, так и программную составляющие) с применением бинарных классификаторов МІ, основанных на различных математических подходах.

1. Анализ материалов предшествующих работ

Разработка ИМК и их применение в различных прикладных задачах, в том числе и для распознавания моторных образов лево/право, является весьма актуальной. По данной тематике были проведены многочисленные исследования. Так, например, в работе [2] для классификации МІ регистрация сигналов ЭЭГ осуществлялось по системе «паук». Для предобработки данных ЭЭГ применялся метод общего пространственного паттерна (Comon Spatial Pattern или CSP). Для классификации признаков авторами применялся метод линейного дискриминантного анализа (LDA). В исследовании принимали участие 10 человек. Средний показатель точности классификации моторных образов составил 60 %. В работе [3] рассматриваются наиболее перспективные методы классификации данных ЭЭГ, которые применимы в ИМК, например метод, основанный на концепции римановской геометрии, а также методы на основе глубоких искусственных нейронных сетей (ИНС). Полученные авторами результаты говорят о том, что точность классификации в «офлайн» режиме с применением CSP составляет 77.5 %, глубоких искусственных нейронных сетей – 81.7 %, римановской концепции 90.2 %. Однако, точность классификации в режиме «онлайн» значительно снижается и не превышает 70 %. Применение риманова расстояния в качестве классификатора моторных образов представлено в работе [4]. Авторы данной работы описывают применение ИМК для классификации воображаемых движений нижними конечностями человека. В эксперименте участвовали 3 человека. Результаты «офлайн» классификации составили 71 %. В режиме «онлайн», точность классификации упала до значений 65 %. В статье [5] представлено применение глубокого обучения в ИМК. Авторы данной статьи проводили исследование в два этапа: на реальных движениях левой и правой рукой и на воображаемых

движениях. Для этого были созданы два набора данных ЭЭГ. Расположение датчиков, регистрирующих сигналы ЭЭГ, осуществлялось по системе 10-10. Получились следующие группы электродов: лобные – Fpz, Fp1, Fp2, Fz, F1, F2, F3, F4, центральные – Cz, C1, C2, C3, C4, теменные – Pz, P1, P2, P3, P4, затылочные – Oz, O1, O2. Для классификации использовалась СНС EEGNet. Точность распознавания реальных движений составила 73 %, а воображаемых 75 % на тестовом наборе данных.

Авторы работы [6] описывают применение СНС для классификации данных ЭЭГ. Электроды, регистрирующие сигналы ЭЭГ, были расположены по системе 10-20. Набор данных составлялся из двух сессий, запись которых происходила в разные дни. Точность классификации с помощью аппарата СНС составила 68.77 %. В исследовании [7] авторы рассматривают применение в качестве классификаторов моторной активности многослойный персептрон (МП), радикальную базисную функцию (РБФ), линейную нейронную сеть (ЛНС), вероятностную нейронную сеть (ВНС). Точности классификации составили: МП – 70 %, ЛНС – 55 %, ВНС – 55 %, РБФ – 85 %. В работе [8] авторы исследуют три типа архитектур ИНС в задачах классификации моторной активности: NN_LSTM, NN_ConvLST и NN_ResNet. Расположение электродов, регистрирующих электрическую активность мозга, осуществлялось по системе наложения электродов 10-20. Точность классификации реальных движений в режиме «офлайн»: NN_LSTM – 85 %, NN_ConvLST – 78 %, NN_ResNet – 91 %.

Проведенный обзор предшествующих исследований позволяет сделать следующие выводы. Во-первых, средняя точность распознавания моторных образов с помощью ИМК в режиме «онлайн» находится в диапазоне от 60-75 % и требует повышения. Во-вторых, следует отметить, что более высоких точностей классификации в работах [7] и [8] удалось достичь благодаря применению промышленного стационарного оборудования, имеющего более высокую точность регистрации данных, но не имеющего возможность использования в переносных ИМК. Так же исследователями отмечается тот

факт, что испытуемые заранее проходят подготовку к сеансам записи данных ЭЭГ (фактически записи ЭЭГ представляют собой дикторозависимые наборы данных).

Целью данного исследования является разработка автономного переносного ИМК асинхронного типа, работающего на принципе выделения и анализа паттернов ЭЭГ, связанных с воображаемыми движениями оператора, обеспечивающего точность классификации в режиме «онлайн» не ниже 65 % на дикторонезависимых наборах данных.

Чтобы достичь указанной цели в процессе работы был решен целый ряд междисциплинарных задач, как при реализации аппаратной, так и программной частей системы:

- по материалам открытого ресурса «Open BCI» [9] проведена разработка автономной переносной нейрогарнитуры, включающей в себя 16-ти канальную регистрирующую аппаратуру, способную регистрировать ЭЭГ, обрабатывать и передавать данные по радиоканалу стандарта Wi-Fi на персональный компьютер (ПК);
- на языке Python разработано комплексное программное обеспечение для ПК, позволяющее принимать регистрируемые данные в режиме «онлайн», проводить их предобработку, выделение паттернов, классификацию используя различные математические подходы, формировать управляющие команды, сохранять полученные результаты в базу данных (БД) и обеспечивать всевозможную визуализацию процессов работы системы.

Проведено исследование влияния различных архитектур бинарных классификаторов, базирующихся на применении разных математических подходов (персептрон Розенблатта, LDA, полносвязный персептрон, CNN ResNet) к их реализации на точность классификации в задачах распознавания MI. Также проведено исследование влияния на точность классификации различных оптимизаторов. Для оценки качества работы бинарных классификаторов были использованы стандартные метрики: Accuracy, Precision, Recall, F1 мера.

2. Разработка аппаратно-программной части ИМК

Для обеспечения реализации асинхронного ИМК необходимо решить задачи из разных областей науки: радиотехники, нейробиологии, математического моделирования и др.

С точки зрения радиотехники и электроники, основываясь на проведенном анализе современных технических средств, для регистрации ЭЭГ сигналов необходимо обеспечить реализацию аппаратно-программного комплекса с характеристиками не хуже чем: полоса регистрируемых частот 0,01-80 Гц с частотой дискретизации не ниже 250 Гц; входное сопротивление усилителей биопотенциалов (УБП) не ниже 1000 МОм; собственные шумы УБП не выше 1 мкВ; количество регистрируемых каналов не менее 8-ми; беспроводная передача регистрируемых сигналов в режиме «онлайн»; малогабаритность и автономность регистрирующей аппаратуры.

Более того для обеспечения удобства использования ИМК (как малогабаритного переносного технического средства) целесообразна разработка быстро-устанавливаемой/быстросъемной конструкции нейроинтерфейса с обеспечением качества регистрации ЭЭГ сигналов не хуже, чем у стационарных аналогов, выпускаемых промышленно и использующих классические металлические электроды AgCl.

Точность классификации сигналов ЭЭГ напрямую зависит от качества регистрируемых биоэлектрических сигналов. В силу ряда причин избавиться от различного рода помех не представляется возможным. Однако можно добиваться минимизации таких помех присутствующих в регистрируемых сигналах и тем самым повышать точность классификации. Подавляющее большинство помех возникает при съеме и передаче электрического сигнала с поверхности кожа-электрод на входы усилителей биопотенциалов. Поэтому схемотехническая реализация устройств съема электроэнцефалографической информации – электродов, приобретает ключевую роль в рамках всего ИМК.

Применение стандартных электропроводных электродов AgCl в системах ИМК затруднительно из-за трудностей установки/съема и необходимости

использования электропроводного геля. Вследствие этого целесообразно использовать активные (с предусилением) резистивно-емкостные или емкостные электроды «сухого типа».

Для анализа технических характеристик было проведено сравнение беспроводных профессиональных медицинских ЭЭГ систем Российского производства, присутствующих в настоящее время рынке. Также был проанализирован международный рынок нейрогарнитур, отличающихся от профессиональных медицинских ЭЭГ систем упрощенной реализацией, связанной с уменьшением числа регистрируемых каналов, переходом на так называемые «сухие» электроды для обеспечения быстросъемной конструкции.

Проведя анализ Open Source проектов по разработке ЭЭГ комплексов был выбран проект OpenBCI [9], на основе материалов которого и проведена разработка макета ИМК в данной работе.

Структурная схема аппаратной части устройства регистрации ЭЭГ приведена на рис. 1.




Рис. 1. Структурная схема аппаратной части устройства регистрации ЭЭГ.

Управление устройством осуществляет 32-х разрядный микроконтроллер PIC32MX250F128B. Микроконтроллер питается от напряжения 2.3-3.6 В, потребляет ток порядка 20 мкА и имеет архитектуру, ориентированную под ассемблер и язык “С”. Также микросхема имеет: внутренний осциллятор; программируемые генераторы PLL и генераторы тактовых импульсов; отказоустойчивый монитор часов (FSCM); независимый сторожевой таймер;

систему быстрых пробуждений и запуска; режимы управления с низким энергопотреблением (Sleep и Idle); интегрированный сброс при включении питания и сброс при отключении питания; поддержку форматов передачи данных I2S, LJ, RJ и DSP и протоколов взаимодействия SPI, I2C; модуль 10-битного АЦП; 10 аналоговых входов; блок измерения времени заряда (CTMU) с поддержкой емкостного распознавания касания; возможность измерения температуры на кристалле; пять таймеров общего назначения (пять 16-битных и до двух 32-битных таймеров/счетчиков); пять модулей сравнения выходных данных (OC); пять модулей захвата ввода (IC); модуль часов и календаря реального времени (RTCC); полноскоростной OTG-контроллер, совместимый с USB 2.0; два модуля UART (12,5 Мбит/с) с поддержкой протоколов LIN 2.0 и IrDA; два четырехпроводных модуля SPI (25 Мбит/с); два модуля I2C (до 1 Мбод) с поддержкой SMBus; PPS, чтобы разрешить переназначение функций; до 256 КБ Flash памяти и 64 КБ SRAM памяти.

Микроконтроллер получает регистрируемые данные от двух независимых малошумящих 8-ми канальных аналого-цифровых преобразователя (АЦП) ADS1299IPAG, включающих в себя по 8 УБП. Также в микроконтроллер поступают данные от трех-осевого МЭМС-акселерометра, построенного на микросхеме LIS3DH. LIS3DH это маломощный высокопроизводительный трехосный линейный акселерометр, относящийся к семейству «нано», с цифровым стандартным последовательным интерфейсом I2C/SPI. Микросхема акселерометра имеет возможность пользователю динамически выбирать диапазоны измерений $\pm 2g/\pm 4g/\pm 8g/\pm 16g$ и способна проводить измерение ускорений с выходными скоростями передачи данных от 1 Гц до 5,3 кГц.

Все регистрируемые данные могут записываться на SD карту, либо передаваться по радиоканалу на ПК. В качестве радиопередающих модулей использованы микросборки RFD22301 (стандарт Bluetooth) и ESP-12E (стандарт Wi-Fi). Микросборка RFD22301 включает в себя высокопроизводительный трансивер стандарта Bluetooth 4.0 со встроенным ARM микроконтроллером Cortex M0, который можно программировать с

помощью простого в использовании Arduino IDE с использованием расширений Rfduino. Микроконтроллер имеет в своем составе средства АЦП, I2C, SPI, UART и GPIO. Микросборка ESP-12E построена на основе системы на кристалле (SoC) ESP8266. ESP8266 поддерживает беспроводной стандарт 802.11 b/g/n; 2 режима работы Wi-Fi Direct (P2P) и soft-AP. В нее интегрирован 32-битный микроконтроллер, стек протокол TCP/IP, а также генераторы PLL и блок управления питанием.

В реализованном ПАК для подключения аппаратуры регистрации к ПК с целью передачи регистрируемых данных ЭЭГ сигналов был использован стандарт Wi-Fi в силу его более высокой пропускной способности, возможности быстрого подключения к локальной сети и увеличенной дальности радиосвязи.

Блок питания устройства на входе имеет КМОП регулятор напряжения +3,3 В, построенный на микросхеме MCP1754T. Регулятор MCP1754T имеет диапазон входных напряжений от 3,6 В до 16,0 В и может выдавать выходной ток до 150 мА. Далее блок питания включает в себя инвертор напряжения (DC-DC преобразователь) построенный на микросхеме LM2664M6. Данный КМОП преобразователь напряжения с подкачкой заряда инвертирует положительное напряжение в диапазоне от 1,8 В до 5,5 В в соответствующее отрицательное напряжение от -1,8 В до -5,5 В. Далее для обеспечения двухполюсного питания УБП и АЦП в схему блока питания добавлены линейные стабилизаторы с низким падением напряжения отрицательной (-2,5 В) и положительной (+2,5 В) полярности построенные на микросхемах TLV70025QDDCRQ1 и TPS72325DBVR.

Вся основная аналого-цифровая обработка сигналов осуществляется двумя 8-ми канальными микросхемами ADS1299IPAG. Поэтому основные технические характеристики всего устройства, связанные с качеством регистрируемых сигналов, напрямую зависят от характеристик данных микросхем. Микросхема ADS1299IPAG имеет в своем составе восемь малошумящих 24-разрядных дельта-сигма (Δ - Σ) АЦП (собственные шумы

усилителей и АЦП не более 2 мкВ от пика до пика). АЦП имеют предварительные усилители с программируемым коэффициентом усиления и встроенный внутренний эталонный генератор.

Блок мультиплексоров, включенный в микросхему ADS1299, позволяет гибко настраивать режимы переключения сигналов для каждого ЭЭГ канала. Это необходимо для диагностики, калибровки и настройки подсистем устройства регистрации ЭЭГ. На рис. 2 показана схема переключений мультиплексора для одного канала.




Рис. 2. Схема переключений входного мультиплексора для одного ЭЭГ канала.

Выходы SRB1, SRB2 и BIAS_IN являются общими для мультиплексоров всех каналов. Выводы SRB1 и SRB2 подключаются в случае использования униполярной схемы включения усилителей. Выводы BIAS_IN и BIASREF используются для подачи на входы усилителей необходимого напряжения смещения. При использовании режима активного подавления синфазных сигналов (помех). Инструментальные дифференциальные усилители OY1- OY8 измеряют дифференциальные сигналы, где точка синфазного напряжения является средней точкой между положительным и отрицательным аналоговыми входами. Благодаря дифференциальному съему сигнала большинство

синфазных помех наводимых на теле человека отсеиваются, однако этого недостаточно. На человеческое тело подобно антенне происходит наведение большого числа синфазных помех и вследствие этого оно склонно к значительным дрейфам синфазных сигналов. Такие синфазные дрейфы приводят к увеличению входного сигнала и выходу его за пределы динамического диапазона АЦП. Для усиленного подавления синфазных сигналов используется вывод (BIAS) встроенного усилителя смещения, который обычно подключается к ушному электроду. Функция усилителя смещения состоит в том, чтобы подавать напряжение смещения в противофазе от наводимого синфазного напряжения на кожу и поддерживать, таким образом, синфазные напряжения на рабочих электродах в пределах допустимого диапазона.

Внешний вид аппаратной части 16-ти канального ИМК, разработанного по материалам открытого источника Open BCI [9] представлен на рис. 3.




Рис. 3. Внешний вид аппаратной части разработанного ИМК.

Наложение электродов осуществлялось по системе 10-20. Всего было использовано 16 каналов регистрации ЭЭГ. Локации электродов при выполнении записей, виды записей ЭЭГ, настройки параметров аппаратуры ИМК, методики проведения экспериментов подробно описаны в работе [10].

В результате проведения экспериментов была сформирована база данных (БД) 7-ми минутных записей ЭЭГ, включающая в себя более 300 образцов. Причем записи ЭЭГ были как дикторозависимые (один и тот же оператор,

прошедший предварительную тренировку), так и дикторонезависимые (различные операторы без предварительной подготовки).

Регистрируемые аппаратной частью ИМК данные ЭЭГ передавались по беспроводному радиоканалу Wi-Fi на ПК с разработанным на языке Python ПО, которое должно быть установлено и запущено.

Представление оператором произвольных моторных актов (движения рук, ног и др.) вызывает контралатеральную моторному акту десинхронизацию сенсомоторных ритмов в коре больших полушарий головного мозга. При этом для организации работы ИМК необходимо сначала проводить построение характеристик, вычисление параметров обрабатываемых пространственно-временных сигналов ЭЭГ, математическое моделирование исследуемых процессов, а также обучение (в том числе глубокое обучение СНС) и выполнение алгоритмов с целью классификации моторики движений правой или левой рукой.

Все рассматриваемые ниже модели обработки и классификации сигналов ЭЭГ были реализованы в виде программного решения. Разработанное ПО имеет модульную архитектуру с централизованным хранением информации. Структурная схема ПО, реализующего распознавание моторики (воображаемой и реальной) приведена на рис. 4. В БД хранятся оцифрованные сигналы ЭЭГ, параметры нейроклассификатора, а также метки времени и идентификаторы экспериментов в унифицированном виде, что позволяет быстро переобучать нейроклассификатор под различные конфигурации (дикторозависимые и дикторонезависимые). Предусмотрена возможность хранения истинной (ground truth) разметки движений для получения различных метрик адекватности нейроклассификатора, таких как точность, ROC AUC, F1-мера и др. Данные метрики вычисляются в модуле статистики и позволяют оценить эффективность классификации.

Получение оценок может происходить на сформированной базе записей в режиме доступности всех данных (режим «офлайн») и режиме «квази-онлайн»,

когда на вход нейроклассификатора подаются данные со скоростью, равной реальной скорости получения данных с датчиков на испытуемом.




Рис. 4. Структурная схема взаимодействия модулей разработанного ПО.

Подобный режим позволяет всесторонне оценивать различные архитектуры нейроклассификаторов на основе уже имеющихся экспериментальных данных.

При первоначальных опытах с использованием программы OpenVibe, для предобработки использовался аппарат CSP (способ декомпозиции мультивариативного сигнала на аддитивные компоненты), а для классификации такие методы, как LDA и SVM (метод опорных векторов) [10]. В результате проведения экспериментов на полученных данных максимальная средняя точность классификации в режиме «офлайн» составила 74,90 % для дикторозависимого случая.

Финальным этапом предобработки данных в разработанном ПО является формирование входных тензоров одинакового размера для нейроклассификатора. Например, из 11 сессий получается 440 отрезков,

соответствующих одному и второму классам. Количество отрезков каждого класса в полученном датасете сбалансированное, что является важным фактором при объективной оценке бинарного классификатора – метрики точности (ассигасу) и F1-меры [11]. Полученный датасет был разбит на обучающую и валидационную выборки в отношении 0,9:0,1.

В рамках данной работы было проведено исследование нескольких классификаторов, базирующих на разных математических подходах: LDA, правило Хебба, многослойный персептрон и СНС, представляющая собой повторяющиеся части архитектуры, которые состоят из некоторого набора различных слоев (ResNet) [12].

3. Реализация различных математических подходов для построения бинарных классификаторов в ИМК

LDA также известный как нормальный дискриминантный анализ (NDA) или анализ дискриминантных функций (DFA) представляет собой процедуру моделирования распределения данных для каждого класса и использует теорему Байеса [13] для классификации новых точек данных. Теорема Байеса дает оценку условной вероятности. Алгоритмы LDA решают задачу отношения входного вектора к наперед заданным классам. LDA выделяет линейную комбинацию признаков, которая позволяет линейно разделить несколько классов, снижая при этом размерность входного вектора. Формально, LDA описывается следующим образом (в данном случае, для задачи бинарной классификации ЭЭГ данных) [14]:

$$\delta(x) = x \cdot \left(\sigma^2 (\mu_0 - \mu_1) - 2\sigma^2 (\mu_0^2 - \mu_1^2) + \ln \left(\frac{P(w_0)}{P(w_1)} \right) \right), \quad (1)$$

где $\delta(x)$ – LDA для входного вектора x ; μ_0, μ_1 – вычисленное среднее двух классов (в геометрическом смысле); σ^2 – общая внутриклассовая дисперсия; $P(w_0), P(w_1)$ – априорные вероятности для классов $\{0,1\}$, которые могут быть получены оценкой статистик по доступному набору данных.

Основными недостатками LDA применительно к задачам классификации МІ в ЭЭГ являются:

- очевидно, что при использовании метода LDA на данных, с перекрывающимися статистиками, невозможно построить линейно разделимое представление признаков;
- данные должны быть маркированы, что не подходит для парадигмы обработки данных «обучение без учителя» [15].

Первый недостаток LDA ограничивает его применение в настоящей работе, т.к. сигналы ЭЭГ имеют сложную структуру и их статистики (моменты i -го порядка [16]) практически неразличимы. Для выделения информации из подобных данных необходимы нелинейные подходы, основным из которых является аппарат ИНС и СНС [15].

Нейронаучная теория Хебба указывает на адаптацию и изменение нейронов мозга в процессе обучения. При обучении вес w_i каждого нейрона изменяется пропорционально произведению входного и выходного сигналов соответствующего нейрона. Формально, правило Хебба можно выразить следующим образом [15]:

$$\Delta w_i = \alpha x_i y, \quad w_i(t+1) = w_i(t) + \Delta w_i, \quad (2)$$

где Δw_i – изменение i -го [синаптического] веса сети; x_i – данные на i -м входе нейрона; y – отклик нейрона; α – коэффициент обучения.

Формализация этого выражения не накладывает ограничений на амплитуды (значения модулей) весов и выходных сигналов. Для нормализации можно использовать различные эвристики, такие как стандартизация входных данных; введение коэффициента регуляризации и др. [15]. В настоящее время существует расширение правила Хебба на многослойные [17] и рекуррентные сети [18]. Однако также существует недостаток – правило Хебба работает в парадигме «обучения без учителя», таким образом, в решаемой задаче классификации ЭЭГ сигналов с наперед заданными метками его применение нецелесообразно.

В ИНС используется подход обучения на некотором обучающем множестве объектов. Эффективность ИНС во многом зависит от результатов обучения, а в частности того, насколько удалось приблизиться к локальному минимуму функции ошибки. Значительное влияние на процесс обучения оказывает репрезентативность обучающей выборки [15]. Под репрезентативностью понимается наличие в выборке достаточного количества разнообразных объектов, наиболее полно отражающих правила и закономерности, которые должны быть обнаружены ИНС. В процессе обучения ИНС свободные параметры настраиваются посредством моделирования среды, в которую эта сеть встроена. Тип обучения определяется способом подстройки этих параметров [19].

Розенблаттом был предложен эвристический алгоритм обучения нейрона, основанный на принципах, нейрофизиологии. Экспериментально было обнаружено, что при синхронном возбуждении двух связанных нервных клеток синаптическая связь между ними усиливается. Чем чаще синапс угадывает правильный ответ, тем сильнее становится связь. Если же синапс начинает часто ошибаться или вообще перестает использоваться, связь ослабевает, информация начинается забываться. Таким образом, память реализуется в синапсах. В математической модели нейрона роль памяти играет вектор синаптических весов w . Рассмотрим случай, когда входные и выходные значения имеют бинарный характер.

Если ответ $a(x_i)$ совпадает с y_i , то вектор весов не изменяется. Если $a(x_i) = 0$ и $y_i = 1$, то вектор весов w увеличивается. Увеличивать имеет смысл только те веса w_i , которые соответствуют ненулевым компонентам x_{ji} , так как изменение других компонент не повлияет на результат. Поэтому w полагается, как [15]:

$$w = w + \eta x_i, \quad (3)$$

где η – некоторая положительная константа, называемая темпом обучения.

Если $a(x_i) = 1$ и $y_i = 0$, то вектор весов уменьшается:

$$w = w - \eta x_i. \quad (4)$$

Поскольку все величины бинарные, эти три случая легко объединить в одну формулу [19]:

$$w = w - \eta(a(x_i) - y_i)x_i. \quad (5)$$

Очевидным недостатком данного типа персептрона является его линейность, что накладывает ограничения на использование этого метода в задачах классификации сигналов ЭЭГ.

Развитием персептрона Розенблата становится многослойный персептрон (fully-connected network, МП) с функциями активации, которые вносят нелинейность в процесс вычисления отклика сети. При этом сеть можно описать рекуррентными соотношениями [20]:

$$y_l = W_l x_l, \quad x_l = \phi_l(y_{l-1}), \quad (6)$$

где $x = x_0$ – вход сети; $y_l = f(x)$ – выход сети; W_l – матрица весов l -го слоя; ϕ_l – функция активации.

Вполне очевидно, что существует необходимость построения бинарного классификатора паттернов ЭЭГ, используя несколько слоев МП, в том числе и сверточных.

Архитектура СНС ResNet состоит из наборов макро-слоев, слоев с повторяющейся архитектурой. Каждый макро-слой, состоящий из набора обычных слоев, выполняющих определенные функции, представляет собой сверточный слой (С-слой). Входные сигналы на слои подаются в виде матриц с сохранением топологических отношений [21]. За каждым сверточным слоем в сети следует слой подвыборки (S-слой). Визуально общее взаимодействие слоев и связи нейронов С-слоя с картами нейронов S-слоев показаны на рис. 5. Причем видно, что 1-й и 2-й нейроны С-слоя имеют свои рецептивные поля (РП) на входных картах S-слоев. Все нейроны С-слоя имеют одни и те же настраиваемые (связанные) веса. Шаг пересечения РП нейронов на S-слоях

задается при построении общей архитектуры СНС. Каждый нейрон С-слоя представляется в виде структуры, показанной на рис. 6.




Рис. 5. Визуализация взаимодействия С- и S-слоев СНС ResNet.




Рис. 6. Нейрон С-слоя.

Операция свертки, происходящая в С-слоях, представляется выражением [21];

$$p = b + \sum_{k=0}^{K_C-1} \text{Ядро}_k * x_{n+k}, \quad (7)$$

где $\text{Ядро}[k]$ – веса нейрона; b – смещение n -го нейрона; K_C – общее количество нейронов; $x[n+k]$ – входные данные для n -го нейрона.

Данные ЭЭГ сигналов, преобразованные в бинарные значения, подаются на входы слоев в виде матриц из нулей и единиц имеющих различные комбинации бинарных представлений.

Взвешенная сумма p поступает на вход функции активации, которая и определяет реакцию нейрона на воздействие. Наиболее распространенными являются ReLU-функции (табл. 1), которые и были использованы в данной работе.

Таблица 1. Виды ReLU-функций.

Математический вид	Особенности
$y(p) = \max(0, p)$	Наиболее простая в вычислительном плане функция, используется в относительно больших сетях
$y(p) = \ln(1 + e^p)$	Гладкая аппроксимация выпрямительной (rectified) функции.
$y(p) = \max(0, p + Y),$ $Y \approx N(0, \sigma(p))$	Где $N(0, \sigma(p))$ – гауссов шум. Применяется в приложениях компьютерного зрения.
$y(p) = \begin{cases} x, & \text{если } x > 0 \\ 0,001x, & \text{иначе} \end{cases}$	Неплотная (leaky) ReLU-функция.
$y(p) = \begin{cases} p, & \text{если } p > 0 \\ ap, & \text{иначе} \end{cases} \quad (8)$	Параметр a выбирается в процессе построения, при $a < 0$ функция принимает вид (9). Функция организует сеть с максимальным выходом (maxout).
$y(p) = \max(p, ap) \quad (9)$	

Использование СНС для решения задач, где требуется большое количество параметров, исчисляемое сотнями миллионов, ограничено из-за одной проблемы. Она связана с возникновением взрывного градиента, который образуется при увеличении количества сверточных слоев, например, в таких архитектурах как VGG [22] или AlexNet [23]. Это происходит из-за того, что при прямом распространении ошибки, большое количество слоев “затирает” значения градиента, которые были в первых блоках нейронной сети [12]. На рис. 7 представлена схема появления взрывного градиента при прямом распространении ошибки.




Рис. 7. Появление взрывного градиента при использовании прямой последовательности сверточных слоев.

На рис. 7 цифрами обозначено накопление градиента. Видно, что с увеличением количества слоев градиент стремительно возрастает. Решением данной проблемы является добавление пропускающих слоев (Residual Layers) и инициализации весов, которые появились в новой архитектуре ResNet [12]. Такая архитектура представляет собой повторяющиеся части макро слоев СНС. Благодаря использованию пропускающих слоев и слою нормализации батча (Batch Normalization, BN) [24], удастся решить проблему взрывного градиента при построении глубоких сетей. Использование только пропускающих слоев, оказывается, недостаточным, т.к. градиент взрывается еще быстрее (рис. 8).




Рис. 8. Появление взрывного градиента при добавлении пропускающих слоев к прямой последовательности сверточных слоев.

Одним из решений может послужить использование нормировочного коэффициента, например, $1/\sqrt{2}$. Тогда прямое распространение будет выглядеть, как представлено на рис. 9.




Рис. 9. Схема накопления градиента с использованием нормировочного коэффициента.

Из рис. 9 видно, что при помощи нормировочного коэффициента решена проблема кумулятивного градиента, но появилась другая проблема. После всех слоев сети появляется один и тот же градиент. Решением данной проблемы служит специальный слой нормализации BN, который необходимо

использовать перед каждым новым слоем. Пример распространения градиента со слоями BN показан на рис. 10.




Рис. 10. Схема накопления градиента с использованием пропускающих слоев и слоев BN.

Подобная архитектура позволяет создавать глубокие сети из однотипных блоков. Благодаря слою BN, нейронная сеть каждый раз обучается на измененных данных. Такая архитектура и была использована в настоящей работе для построения бинарного классификатора. В рамках исследования было экспериментально найдено оптимальное количество повторяющихся блоков применительно к задачам классификации ЭЭГ равное восемнадцати. Благодаря рассмотренным особенностям архитектуры ResNet и проведенному архитектурному поиску, бинарный классификатор, построенный на ее основе наилучшим образом подходит для задач классификации МІ в разработанном ИМК.

Далее по стандартным метрикам Accuracy, Precision, Recall и F1 мера было проведено исследование эффективностей методов оптимизации работы СНС.

4. Используемые методы оптимизации

Входной тензор классифицируемых данных ЭЭГ в бинарном виде имеет вид: $X \in R^{B \times C \times T}$, где B – число батчей (мини-пакетов); C – число каналов; T – число отсчетов сигнала и Y^B – количество меток, соответствующих каждому тензору X . Существует функция f , которая способна аппроксимировать X так, что $Y = f(X)$. Однако, для достижения точной

аппроксимации необходимо корректировать функцию $f(X)$. Для решения такой задачи и существуют алгоритмы оптимизации, базирующие на разных методах: градиентного спуска, адаптивной скоростью обучения и второго порядка.

Алгоритм стохастического градиентного спуска (Stochastic Gradient Descent, SGD) [17, 25] – метод выпуклой оптимизации, который имеет большую популярность так как уменьшает сложность вычисления градиентного спуска с $O(N)$ до $O(1)$. Математический вид SGD представлен формулой:

$$x_t \leftarrow x_{t-1} - a * \nabla f_t(x), \quad (10)$$

где x_t – текущее значение параметра; x_{t-1} – прошлое значение параметра; a – скорость схождения; $\nabla f_t(x)$ – градиент функции $f_t(x)$.

Основной проблемой SGD является застревание в седловых точках и достижение локального минимума. Решением данной проблемы без изменения алгоритма является динамическое изменение скорости обучения a .

Adaptive Moment Estimation (ADAM) [18, 26] – алгоритм градиентного спуска первого порядка, который использует две смещенные оценки импульсов и их корректировку, что позволяет эффективно минимизировать большие градиенты. Математически вид ADAM можно представить формулами

$$m_t \leftarrow \beta * m_{t-1} + (1 - \beta) * \nabla w_t, \quad v_t \leftarrow \gamma * v_{t-1} + (1 - \gamma) * (\nabla w_t)^2, \quad (11)$$

где m – первый импульс; v – второй импульс.

Применение импульса равносильно использованию скользящего среднего за все время обработки. Поскольку в начале обучения значения m_t и v_t малы, то используются нормированные значения:

$$\hat{m}_t = \frac{\hat{m}_t}{1 - \beta^t}; \quad \hat{v}_t = \frac{\hat{v}_t}{1 - \gamma^t}, \quad (12)$$

где $\hat{m}_t$ и $\hat{v}_t$ – нормированные векторы; β и $\gamma \in [0, 1]$ позволяют уменьшить влияние m_t и v_t при значениях β и $\gamma \approx 1$.

Итоговое значение веса вычисляется по формуле:

$$w_t \leftarrow w_{t-1} - a \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \varepsilon}, \quad (13)$$

где w_t – значение текущего веса; w_{t-1} – значение прошлого веса; a – скорость обучения.

Еще один распространенный алгоритм квадратичной оптимизации – это метод сопряженных градиентов. Он позволяет не искать обратный гессиан H^{-1} , т.к. применяет итеративный спуск в сопряженных направлениях. Данный алгоритм является улучшением наискорейшего спуска, который имеет проблему, связанную с передвижением зигзагами в квадратичной оптимизации.

Пусть d_{t-1} направление предыдущего поиска, тогда в точке минимума, где алгоритм поиска завершается, производная равная нулю, т.е. $\nabla_{\Theta} J(\Theta) \times d_{t-1} = 0$. Т.к. производная в точке d_{t-1} определяет текущий градиента, то $d_t = \nabla_{\Theta} J(\Theta)$ не имеет никакой информации о предыдущем значении. Таким образом, d_t ортогонально d_{t-1} .

В методе сопряженных градиентов прошлое и текущее направления сопряжены $d_t^T H d_{t-1} = 0$. Таким образом результаты, полученные ранее, влияют на то, что получится дальше. Математическое представление метода на каждом шаге оптимизации можно представить как:

$$d_t = \nabla_{\Theta} J(\Theta) + \beta_t d_{t-1}, \quad (14)$$

где β_t – коэффициент, определяющий степень влияния предыдущего направления.

Для расчета сопряженности, обычно, используют два метода, благодаря которым отпадает необходимость высчитывать H^{-1} . Это метод Флетчера-Ривса:

$$\beta_t = \frac{\nabla_{\Theta} J(\Theta_t)^T \times \nabla_{\Theta} J(\Theta_t)}{\nabla_{\Theta} J(\Theta_{t-1})^T \times \nabla_{\Theta} J(\Theta_{t-1})}. \quad (15)$$

И метод Полака-Рибьера:

$$\beta_t = \frac{(\nabla_{\Theta} J(\Theta_t) - \nabla_{\Theta} J(\Theta_{t-1}))^T \times \nabla_{\Theta} J(\Theta_t)}{\nabla_{\Theta} J(\Theta_{t-1})^T \times \nabla_{\Theta} J(\Theta_{t-1})}. \quad (16)$$

Метод Полака-Рибьера имеет лучшую сходимость, чем метод Флетчера-Ривса.

Еще один рассмотренный в данной работе алгоритм оптимизации – это алгоритм Бroyдена-Флетчера-Гольдфарба-Шанно (BFGS) [19-21]. Это квазиньютоновский алгоритм оптимизации второго порядка, который пытается решить основную проблему алгоритма Ньютона – большое количество используемой памяти при оптимизации $O(k^3)$, где k – количество параметров сети. Решением является аппроксимационная матрица M_t для обратного гессиана H^{-1} , регулируемая на каждом итерации обучения. Этот шаг позволяет уменьшить используемую память до $O(k^2)$. Однако, по-прежнему, уходит достаточно большое количество вычислительных ресурсов на вычисление значений параметров, которые исчисляются сотнями миллионов и десятками миллиардов. Поэтому часто используется усовершенствованный алгоритм L-BFGS (Less Memory BFGS) [27]. Идея заключается в том, что за M_{t-1} принимается единичная матрица I , что позволяет уменьшить потребляемую память до $O(k)$.

И наконец, четвертым алгоритмом оптимизации, примененным в разработанном ИМК, является алгоритм Левенберга-Марквардта. Это алгоритм оптимизации второго порядка. Он использует для оптимизации информации, полученной из гессиана системы, в нашем случае ИНС. Основной идеей, лежащей в основе алгоритма Левенберга-Марквардта является аппроксимация гессиана, построенного по параметрам ИНС, с помощью якобиана, построенного по весам сети и входным тензорам [28]. Формально матрица якобиана выражается как:

$$J = \begin{bmatrix} \frac{\partial e_1(P_1)}{\partial W_1} & \dots & \frac{\partial e_1(P_1)}{\partial W_T} \\ \vdots & \ddots & \vdots \\ \frac{\partial e_{MP}(P_P)}{\partial W_1} & \dots & \frac{\partial e_{MP}(P_P)}{\partial W_T} \end{bmatrix}. \quad (17)$$

где e_i – ошибка для i -го выхода ИНС; P – количество объектов в обучающей выборке; W – веса ИНС.

Вычислив якобиан для ИНС и обучающего набора данных, можно аппроксимировать гессиан и обновить параметры (веса) ИНС [29]:

$$H \approx J^T J + \mu I, W_n = W_{n-1} - (H^{-1}g). \quad (18)$$

где H – гессиан по параметрам ИНС; I – единичная матрица; μ – коэффициент регуляризации, обновляемый на каждом шаге алгоритма.

Очевидно, у алгоритма Левенберга-Марквардта существует два основных недостатка: большой объем памяти, необходимый для хранения матрицы якобиана и нахождения обратной матрицы H^{-1} .

В работе [30] была предложена модификация алгоритма Левенберга-Марквардта, заключающаяся в гибридизации алгоритмов обучения искусственных нейронных сетей первого и второго порядка. Данная модификация позволяет решить проблемы, обозначенные выше, однако в основном на обработке изображений. Учитывая специфику классификации ЭЭГ данных, а в частности, то, что количество значений в тензорах, представляющих собой сигналы от датчиков ЭЭГ значительно меньше, чем количество значений в тензорах с данными для изображений, а также относительно небольшое количество отсчетов, обрабатываемых в единицу времени, целесообразно модифицировать метод Левенберга-Марквардта с использованием промежуточного кеширования результатов. Что и было сделано при реализации ПО.

В основном, оптимизация нейронных сетей ограничена видеопамью (VRAM) вычислителей (GPU, TPU, NPU), с другой стороны, память на диске – достаточно дешева. Таким образом, применительно к задачам обработки ЭЭГ

данных, предлагается ввести в процедуру вычисления Якобиана, распределенные во времени вычисления.

Рассмотрим следующий случай. Пусть количество обучающих примеров (объектов) значительно больше, чем количество весов в сети: $|P| \gg |W|$. Тогда применение алгоритма Левенберга-Марквардта ограничено максимальным значением из пары (P, W) . С другой стороны, вычисление выражений (18) может быть выполнено по частям. Известны различные алгоритмы умножения двух матриц, которые единовременно оперируют только небольшими подматрицами исходных матриц, например алгоритм Штрассена, алгоритм Копперсмита-Виноградова и др. Таким образом, каждая подматрица якобиана может быть рассчитана независимо:

$$J_C = \begin{bmatrix} \frac{\partial e_1(P_{1+K \cdot C})}{\partial W_1} & \dots & \frac{\partial e_1(P_{1+K \cdot C})}{\partial W_T} \\ \vdots & \ddots & \vdots \\ \frac{\partial e_{MP}(P_{P+K \cdot C})}{\partial W_1} & \dots & \frac{\partial e_{MP}(P_{P+K \cdot C})}{\partial W_T} \end{bmatrix}, C \in \left\{0, \frac{P}{K}\right\}, \quad (19)$$

где K – количество строк подматрицы (chunk); C – индекс подматрицы.

После расчета каждой подматрицы ее значения сохраняются в отдельный файл на диске. Последующие операции линейной алгебры можно провести с помощью соответствующих алгоритмов для распределенного вычисления.

После вычисления (18) полученную матрицу H можно загрузить в VRAM и продолжить вычисления на графическом процессоре. Предложенная модификация позволит снять с алгоритма Левенберга-Марквардта ограничение на максимальное количество обучающих примеров в датасете, продиктованное размером VRAM. Следовательно, предложенная модификация имеет ограничение только по количеству настраиваемых параметров модели. Данная модификация также как и рассмотренные другие алгоритмы оптимизации была реализована на языке Python, с использованием фреймворков Dask и PyTorch [31].

5. Классификация моторных образов и обсуждение результатов

Основываясь на теоретических выкладках, представленных в предыдущих разделах, было разработано ПО, реализующее рассмотренные математические модели. Структурная схема взаимодействия блоков разработанного ПО была представлена на рис. 4.

Сформированная, с помощью разработанного ИМК, база 7-ми минутных записей ЭЭГ содержит более 300 образцов. Все записи были сделаны по одной и той же методике измерений, описанной в работе [10].

Разработанное ПО позволяет простым переключением изменять вид используемого бинарного классификатора. Также имеется возможность настройки параметров работы классификатора и изменение типа оптимизатора.

Программа позволяет также легко переключаться между режимами «обучение» или «работа». Режим «работа» осуществляется в режиме реального времени («онлайн»). Все приходящие ЭЭГ данные сразу классифицируются и на экран выводятся усредненные показатели точностей.

Для обучения бинарных классификаторов на основе ИНС и других методов были использованы записи ЭЭГ, взятые из общей БД, сделанные различными операторами в различное время без предварительной подготовки. Соответственно можно сказать, что все записи были дикторонезависимыми.

Для того чтобы провести исследование влияния типа бинарного классификатора на точность классификации были использованы бинарные классификаторы, построенные на основе следующих математических моделей:

- 1) CHC ResNet (18 слоев);
- 2) полносвязный персептрон;
- 3) LDA;
- 4) персептрон Розенблата.

Для того чтобы провести исследование влияния метода оптимизации на точность классификации были взяты следующие методы оптимизации (применительно к классификаторам 1 и 2):

- 1) SGD;
- 2) ADAM;
- 3) BFGS;
- 4) Левенберг-Марквардт.

Используя дикторонезависимые наборы данных, было проведено обучение всех 4-х классификаторов. В результате были полученные усредненные значения метрик Accuracy, Precision, Recall и F1 мера на этапе валидации после прохождения в общей сложности более 1600 эпох обучения. В табл. 2 представлены усредненные оценки каждого исследованного метода бинарной классификации и соответствующего метода оптимизации. Жирным шрифтом выделены лучшие результаты в каждой метрике.

Таблица 2. Среднее значение метрик по серии экспериментов.

Оптимизаторы	Метрики (%)			
	Accuracy	Precision	Recall	F1 мера
CHC ResNet				
SGD	61,37	62,18	59,29	60,70
ADAM	68,31	67,08	68,80	67,97
BFGS	49,30	47,41	49,48	48,42
Левенберг-Марквардт	50,05	48,61	47,51	48,05
Полносвязный персептрон				
SGD	48,50	48,08	48,18	48,13
ADAM	54,63	51,75	56,84	54,17
BFGS	51,07	48,11	53,52	50,54
Левенберг-Марквардт	52,01	49,07	54,19	51,50
Другие методы				
LDA	50,08	49,28	49,89	49,59
Персептрон Розенблата	49,70	48,82	50,71	49,75

На рис. 11 представлены графики изменения значений метрики F1 мера для различных оптимизаторов в зависимости от количества эпох обучения при использовании классификатора на основе CHC ResNet.




Рис. 11. Значения метрики F1 мера при использовании оптимизаторов SGD, BFGS, ADAM, Левенберг-Марквардт.

Из рисунка видно, что оптимизатор на основе метода Левенберга-Марквардта не работает должным образом при валидации на данных ЭЭГ и завершает свою работу на ранних этапах валидации.

Анализируя данные усредненных значений метрик, приведенные в табл. 2 можно сделать вывод о том, что наилучших значений удастся добиться при применении оптимизатора на основе алгоритма ADAM. Значения метрик в «офлайн» режиме при использовании классификатора на основе СНС ResNet составляют: Accuracy 68,31 %, Precision 67,08 %, Recall 68,80 % и F1 мера 67,97 %. Остальные бинарные классификаторы показывают невысокую точность классификации на дикторонезависимых данных. Однако на дикторозависимых данных с предварительным обучением оператора они вполне могут быть использованы, как это было продемонстрировано в работе [10].

Далее была проведена серия экспериментов по классификации МІ (мысленное движение левой либо правой рукой) в режиме «онлайн» в разное время и для разных операторов, но используя одну и ту же методику измерений, представленную в работе [10]. При этих экспериментах использовался бинарный классификатор, построенный на основе СНС ResNet. Усредненные значения метрик в режиме «онлайн» составили: Accuracy 65,92 %, Precision 65,11 %, Recall 66,20 % и F1 мера 66,05 %. Что говорит о

работоспособности разработанного переносного ИМК асинхронного типа и целесообразности его доработки для повышения точностей классификации МІ. Проведенное исследование позволяет сравнить точности классификаций с применением бинарных классификаторов, основанных на совершенно разных математических подходах и оценить влияние алгоритмов оптимизации на точности классификации. Результаты исследования показывают, что в целом применение аппарата СНС для задач классификации МІ по сигналам ЭЭГ в ИМК полностью себя оправдывает.

Заключение

В работе рассмотрены теоретические аспекты применения ЦОС и СНС в задачах распознавания моторики по сигналам ЭЭГ. Разработан асинхронный ИМК на основе распознавания МІ. Приведена структурная схема разработанного ПО, проанализированы экспериментальные результаты.

Проведено исследование нейросетевых и алгоритмически детерминированных классификаторов, методов оптимизации первого и второго порядков. Лучшие показатели метрик, в частности, метрики F1 удалось достичь с помощью макрослоев сверточной нейронной сети, повторяющиеся части архитектуры, которые состоят из некоторого набора различных слоев, т.е. ResNet с 18-ю повторяющимися блоками при использовании оптимизатора первого порядка с адаптивной оптимизацией импульсов ADAM. При использовании других комбинаций классификатора ResNet и оптимизаторов, значения метрик показывают флуктуационные значения около 50 %, т.е. не могут найти корреляционные отношения между данными, полученными с электродов.

Таким образом, комплексные исследования в области разработки теоретических и практических основ асинхронных интерфейсов «мозг-компьютер» для распознавания моторики оператора путем классификации сигналов электроэнцефалограмм с применением СНС, показывают сложность

классификации, базирующуюся на апостериорных данных, полученных с неинвазивных источников информации.

В ходе исследования был разработан асинхронный ИМК, осуществляющий распознавание моторных образов лево/право. Разработанный ИМК является универсальным для широкого круга задач, а также позволяет переобучать нейроклассификаторы для дикторозависимых задач. В дальнейших исследованиях планируется дальнейшее усовершенствование технологии ИМК, повышение устойчивости системы к помехам в канале регистрации ЭЭГ, а также разработка способов усреднения и специализированных метрик адекватности для распознавания МІ в режиме «онлайн».

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

Литература

1. Журавлев Д.В. Система передачи буквенно-цифровой информации на основе частотно-временного анализа сигнала электроэнцефалограммы // Журнал радиоэлектроники. – 2025. – №. 7. <https://doi.org/10.30898/1684-1719.2025.7.15>
2. Suryotrisongko H., Samopa F. Evaluating openbci spiderclaw v1 headwear's electrodes placements for brain-computer interface (BCI) motor imagery application // Procedia Computer Science. – 2015. – Т. 72. – С. 398-405.
3. Kapralov N.V., Nagornova Z.V., Shemyakina N.V. Classification methods for EEG patterns of imaginary movements // Informatics and Automation. – 2021. – Т. 20. – №. 1. – С. 94-132.
4. Журавская А., Станкевич Л.А. Применение неинвазивного интерфейса «мозг-компьютер» для классификации воображаемых движений нижних конечностей человека // Системный анализ в проектировании и управлении. – 2021. – Т. 25. – №. 3. – С. 146-158.

5. Павленко Д.В., Татарис Ш.Э., Овчаренко В.В. Применение глубокого обучения в интерфейсах мозг–компьютер для распознавания движений // Программные продукты и системы. – 2024. – Т. 37. – №. 2. – С. 164-169.
6. Echtioui A. et al. A novel convolutional neural network classification approach of motor-imagery EEG recording based on deep learning // Applied Sciences. – 2021. – Т. 11. – №. 21. – С. 9948.
7. Руннова А.Е. и др. Классификация паттернов двигательной активности на ЭЭГ-данных // Вестник российских университетов. Математика. – 2017. – Т. 22. – №. 5-2. – С. 1127-1132.
8. Асадуллаев Р.Г., Афонин А.Н., Щетинина Е.С. Распознавание паттернов двигательной активности нейронной сетью по непрерывным данным оптической томографии fNIRS // Экономика. Информатика. – 2021. – Т. 48. – №. 4. – С. 735-746.
9. Официальный сайт проекта «OpenBCI». URL: <https://github.com/OpenBCI/> (дата обращения: 01.09.2025).
10. Журавлев Д.В., Голубинский А.Н., Толстых А.А. Разработка методики настройки параметров интерфейсов «мозг-компьютер» для проведения экспериментов по классификации моторных образов в программе OpenVibe // Биомедицинская радиоэлектроника. – 2025. – Т. 28. – № 3. – С. 15-30.
11. Гудфеллоу Я., Иошуа Б., Курвилль А. Глубокое обучение. – Litres, 2017.
12. Shafiq M., Gu Z. Deep residual learning for image recognition: A survey // Applied sciences. – 2022. – Т. 12. – №. 18. – С. 8972.
13. Heuts S. et al. Bayesian analytical methods in cardiovascular clinical trials: why, when, and how // Canadian Journal of Cardiology. – 2025. – Т. 41. – №. 1. – С. 30-44.
14. Li Q., Shao J. Sparse quadratic discriminant analysis for high dimensional data // Statistica Sinica. – 2015. – С. 457-473.
15. Хайкин С. Нейронные сети: полный курс, Издательский дом «Вильямс» // Москва. – 2006. – Т. 1. – С. 104.
16. Буре В.М., Парилина Е.М., Свиркин М.В. Теория вероятностей. – 2008.

17. Miconi T. Hebbian learning with gradients: Hebbian convolutional neural networks with modern deep learning frameworks // arXiv preprint arXiv:2107.01729. – 2021.
18. Siri B. et al. A mathematical analysis of the effects of Hebbian learning rules on the dynamics and structure of discrete-time random recurrent neural networks // Neural computation. – 2008. – Т. 20. – №. 12. – С. 2937-2966.
19. Nawi N.M., Ransing M.R., Ransing R.S. An improved learning algorithm based on the Broyden-Fletcher-Goldfarb-Shanno (BFGS) method for back propagation neural networks // Sixth International Conference on Intelligent Systems Design and Applications. – IEEE, 2006. – Т. 1. – С. 152-157.
20. Ashby W. Design for a brain: The origin of adaptive behaviour. – Springer Science & Business Media, 2013.
21. Ji L. et al. An intelligent diagnostic method of ECG signal based on Markov transition field and a ResNet // Computer Methods and Programs in Biomedicine. – 2023. – Т. 242. – С. 107784.
22. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // arXiv preprint arXiv:1409.1556. – 2014.
23. Krizhevsky A., Sutskever I., Hinton G.E. Imagenet classification with deep convolutional neural networks // Advances in neural information processing systems. – 2012. – Т. 25.
24. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // International conference on machine learning. – pmlr, 2015. – С. 448-456.
25. Nguyen N., Han S. AET-SGD: Asynchronous Event-triggered Stochastic Gradient Descent // arXiv preprint arXiv:2112.13935. – 2021.
26. Kingma D.P. Adam: A method for stochastic optimization // arXiv preprint arXiv:1412.6980. – 2014.
27. Going deeper with convolutions | IEEE Conference Publication | IEEE Xplore. URL: <https://ieeexplore.ieee.org/document/7298594> (дата обращения: 10.09.2025).

28. Shepherd A.J. Second-order methods for neural networks: Fast and reliable training methods for multi-layer perceptrons. – Springer Science & Business Media, 2012.
29. Smith J.S., Wu B., Wilamowski B.M. Neural network training with Levenberg–Marquardt and adaptable weight compression // IEEE transactions on neural networks and learning systems. – 2018. – Т. 30. – №. 2. – С. 580-587.
30. Голубинский А.Н., Толстых А.А. Гибридный метод обучения сверточных нейронных сетей // Информатика и автоматизация. – 2021. – Т. 20. – №. 2. – С. 463-490.
31. PyTorch. URL: <https://pytorch.org/> (дата обращения: 10.09.2025).

Для цитирования:

Журавлев Д.В., Резниченко А.А., Голубинский А.Н., Толстых А.А. Исследование бинарных классификаторов, базирующихся на разных математических подходах при распознавании моторных образов двигательной активности в интерфейсе «мозг-компьютер» асинхронного типа // Журнал радиоэлектроники. – 2025. – №. 11. <https://doi.org/10.30898/1684-1719.2025.11.34>