

# ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ К ДИАГНОСТИРОВАНИЮ ПСИХИАТРИЧЕСКИХ ЗАБОЛЕВАНИЙ НА ОСНОВЕ СИГНАЛОВ ЭЭГ

Nadezhda Shanarova<sup>1</sup>, Mikhail Lipkovich<sup>1</sup>, Marina Pronina<sup>2</sup>, Valery Ponomarev<sup>2</sup>, Andreas Müller<sup>3</sup>, Juri Kropotov<sup>2</sup>

<sup>1</sup>Institute of Problems in Mechanical Engineering, Saint Petersburg, Russia  
nadya.shanarova@gmail.com, lipkovich.mikhail@gmail.com

<sup>2</sup>Institute of the Human Brain of Russian Academy of Sciences, Saint Petersburg, Russia  
proninamarina@mail.ru, valery\_ponomarev@mail.ru, yurykropotov@yahoo.com

<sup>3</sup>Brain and Trauma Foundation, Chur, Switzerland  
andreas.mueller@hin.ch

21 ноября 2024

## Введение

В настоящее время все большее внимание уделяется диагностике психиатрических заболеваний с использованием неинвазивных методов, таких как ЭЭГ, благодаря их доступности и безопасности. Этот метод, обладающий высоким временным разрешением, позволяет выявлять нейрокognитивные процессы, важные для диагностики, и предоставляет дополнительные данные о состоянии мозга. При анализе ЭЭГ-активности используются вызванные потенциалы (ВП) и потенциалы, связанные с событиями (ПСС), которые помогают оценить когнитивные и исполнительные функции, такие как сенсорное восприятие, память и контроль поведения — важные аспекты, которые могут быть нарушены при шизофрении, ОКР и других психических заболеваниях.

**Цель и задачи работы:** Целью настоящего исследования является разработка объективных методов медицинской диагностики психиатрических заболеваний. Одним из подходов к анализу неинвазивных ЭЭГ сигналов является анализ вызванных потенциалов (ВП). Использование когнитивных вызванных потенциалов мозга человека, связанных с событиями, и выделение из них значимых характеристик может служить в качестве объективных признаков с целью дифференциации пациентов с разными психическими расстройствами от здоровых людей. Комбинация данного анализа с алгоритмами машинного обучения, может помочь выявить конкретные биомаркеры заболеваний и повысить качество контроля и диагностики психических расстройств.

Поставленная задача диагностики относится к бинарной классификации по данным электроэнцефалограмм человека, где классами являются контрольная (люди с заболеванием) и экспериментальная группа (люди без диагноза), являющимися отрицательными и положительными классами соответственно. Задача поставлена совместно с представителями кафедры теоретической кибернетики СПбГУ, членом которой является автор исследования, и Институтом мозга человека РАН им. Н.П. Бехтеревой (ИМЧ РАН).

В соответствии с целью исследования были поставлены следующие **задачи**:

1. Разработка характеристик ВП для предоставления их моделям машинного обучения.

2. Определение психического расстройства с помощью алгоритмов машинного обучения и оценка качества классификаторов.
3. Интерпретация результатов и обоснование применимости машинного обучения для определения заболевания.
4. Проверка надёжности полученных результатов.

**Актуальность исследования:** Раннее выявление психических заболеваний, таких как шизофрения, обсессивно-компульсивное расстройство и депрессия, критично, поскольку задержка в лечении может привести к необратимым изменениям в структуре и функции мозга. Современные методы диагностики часто основаны на субъективных оценках, тогда как использование машинного обучения для анализа как ВП, так и сырых сигналов ЭЭГ способствует объективности и точности диагностики. Исследования показывают, что изменения в параметрах активности ЭЭГ, такие как снижение сложности сигналов в лобной области у пациентов с шизофренией, или особенности в сырых сигналах при депрессии, могут служить диагностическими маркерами. Настоящее исследование демонстрирует возможности машинного обучения для диагностики на основе ПСС и сырых ЭЭГ-сигналов, что позволит выделить ключевые нейрофизиологические параметры для последующего использования в диагностике и нейротерапии.

## Материал для исследования

### Данные: выборка

В исследование включены данные 132 здоровых испытуемых (53 человека, средний возраст  $31,8 \pm 8,26$  лет, диапазон 18-50 лет) из проекта HBImed (Human Brain Index) в г. Чур, Швейцария, Санкт-Петербургского государственного университета и Института мозга человека им. Н.П. Бехтеревой РАН. Группа с шизофренией включала 68 пациентов (47 мужчин, средний возраст  $30,6 \pm 7,17$  лет), а группа с ОКР — 63 пациента (30 мужчин, средний возраст  $27,5 \pm 5,15$  лет). Диагностика была проведена специалистами Института мозга человека, и все пациенты имели умеренные или тяжелые когнитивные нарушения на момент исследования. Данные по депрессии включали сырые сигналы ЭЭГ 106 здоровых испытуемых и 68 пациентов с депрессией в состоянии покоя.

### Постановка эксперимента

Для регистрации ПСС использовался тест GO-NOGO парадигмы, позволяющий оценить мозговую систему управления действиями. Испытуемые должны были реагировать на целевые стимулы (GO) и воздерживаться от нажатия на нецелевые (NOGO). В данном эксперименте использовалась модификация теста со зрительными стимулами [?, ?] (Рис. 1).

Испытуемым демонстрировали три категории визуальных стимулов: 20 изображений животных (обозначение 'A'), растений ('P') и людей ('H'). Зрительные стимулы имели одинаковую яркость и размер, с искусственным звуком 70 дБ SPL частотой от 500 до 2500 Гц. Испытания включали четыре категории: А-А, А-Р, Р-Р и Р-Н, сгруппированные в четыре блока по 100 заданий с равной вероятностью для каждой категории.

Перед записью испытуемые тренировались. После каждых 200 испытаний испытуемые отдыхали, сидя прямо перед экраном компьютера, и выполняли задачу, реагируя на пары А-А и воздерживаясь на другие пары.

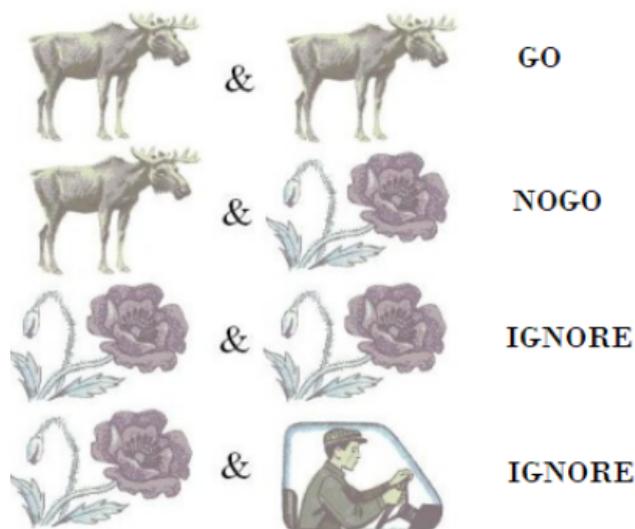


Рис. 1: Примеры зрительных стимулов, использованных в тесте на селективное внимание

### Данные:

#### потенциалы, связанные с событиями

В качестве примера нарушений системы контроля поведения были выбраны такие психические расстройства, как шизофрения и ОКР, а в качестве нейромаркеров когнитивного контроля — 19-канальные ПСС, полученные с помощью модификации теста GO/NOGO парадигм. Каждый сигнал был длительно в среднем 200 мс в четырех вариантах тестирования. Интервалы и топография выбранных сигналов соответствовали волнам P300 и CNV [23].

Данный способ отбора был применен с помощью кластерного анализа. Тем самым были выделены пространственно-временные кластеры, в которых ПСС экспериментальной группы статистически значимо отличались от ПСС контрольной группы. Информация по этим данным, а именно временные интервалы и список каналов, послужили основой применения методов машинного обучения для классификации данных пациентов с разными психическими расстройствами на основании физиологических параметров работы мозга.

ПСС были выбраны для контрольной и экспериментальной групп по каждому заболеванию в следующих условиях:

- «plus1»: условие с изображением животного в качестве первого стимула в пробе и произвольным вторым стимулом. Для каналов T5, O1, O2, T6 был взят интервал от 320 мс до 520 мс после первого стимула.
- «plus2»: условие с изображением животного в качестве первого стимула в испытании и произвольным вторым стимулом. Для каналов P3, Pz, P4 интервал составлял от 900 мс до 1080 мс.
- «NoGo»: условие с изображением животного в качестве первого стимула и изображением растения в качестве второго. Были выбраны каналы C3, Cz, C4, P3, Pz, P4 с интервалом от 300 мс до 500 мс после второго стимула.
- «Go»: условие с изображением животного в качестве обоих стимулов. Интерес представляли каналы C3, Cz, C4, P3, Pz, P4 с интервалом от 250 мс до 450 мс после второго стимула.
- «Р-Н»: условие с изображением растения в качестве первого стимула и изображением человека в качестве второго стимула. Выбранные каналы были C3, Cz, C4 с интервалом от 160 мс до 220 мс после второго стимула.

Данная методика получения ПСС была проведена специалистами в физиологии из Института мозга человека им. Н.П. Бехтеревой РАН.

### **3.4 Данные: Компоненты ВП, полученные с помощью ICA**

Относительно недавно большое распространение получил метод независимых компонент (ICA), в работах по физиологии есть другое название – BSS метод (blind source separation), который позволяет как новый методологический подход в исследованиях когнитивных ВП [6]. В отличие от метода главных компонент (PCA) [4], ICA не требует ортогональности выделяемых компонент и позволяет разложить многоканальные данные таким образом, что, зная один компонент, невозможно ничего сказать о других компонентах. Тем самым, с помощью данного метода на выходе получаем компоненты, имеющие минимальную взаимную информацию, которая является мерой статистической независимости компонент, которая позволит качественно выделить источники генерации волн ВП. Предполагается, что если выделяемые компоненты статистически независимы, то это соответствует истинной природе источников генерации волн когнитивных ВП, порождающих различные компоненты в ПСС. Действительно,

поток информации в мозге, вызванный предъявлением стимула, последовательно активирует различные иерархически организованные области коры так, что источники генерации волн ВП активируются в разные временные интервалы и в разных местах коры.

Таблица 1: Интервалы и условия, выбранные по данным компонент ВП, полученных с помощью ICA (BSS method, blind source separation)

Тип расстройства	№	Интервал GO, мс	Интервал NOGO, мс
ШИЗОФРЕНИЯ	1	1600-1900	1500-1600; 1700-2000
	2	1900-2500	1750-1950; 2000-2350
	3	610-900; 1500-1700	480-600; 610-990; 1200-1400; 1580-1750
	4	400-1100;1200-1450;1700-2150	400-1400;1600-1900
	5	1510-1610; 1680-1800; 2000-2600	1610-1880; 2000-2200
	6	500-900;1520-2000	1520-1780
	7	410-800; 1610-1850	480-800; 860-1200
	8	1200-1500	1300-1500
	9	-	-
	10	-	-
	11	410-550; 600-1000; 1200-1500; 1510-1650; 1700-1950	480-550; 600-1000; 1220-1520; 1550-1650; 1680-1980
ОКР	1	250-400	320-500
	2	450-550	-
	3	180-250	-
	4	-	250-400
	5	290-500	290-410
	6	200-350	120-200
	7	100-160	100-160
	8	-	210-300
	9	-	-
	10	-	300-420
	11	50-120; 180-230	50-120;180-260

Исходя из того, что ICA позволяет разделить смешанный сигнал на составляющие и анализировать эти компоненты отдельно, для разложения ВП на независимые компоненты специалистами в физиологии была проведена методика, описанная в [24], с использованием данного метода к вызванным потенциалам, зарегистрированным в двустимульном GO/NOGO тесте в двух группах пациентов с психическими расстройствами: шизофрения и ОКР, а также к нормативной базе. Компоненты ВП были рассчитаны для двух условий теста: GO и NOGO. Из полученных компонент (11\*2) были отобраны 18 для шизофрении, и 14 для ОКР (см. Рис. 1). Во всех группах были даны интервалы с наибольшей дисперсией найденных компонент ВП, которые отражают функции системы управления действиями и по которым были выявлены достоверные отличия амплитуды от нормативных данных [25, 26, 27]

Таким образом, специалисты в физиологии из ИМЧ РАН разложили многоканальные когнитивные ВП на функционально значимые компоненты и предоставили их с целью последующего их сравнения с соответствующими компонентами в контрольной группе.

### 3.5 Поведенческие данные

Помимо сбора данных ЭЭГ во время эксперимента, ответы испытуемого также записывались с помощью отдельного канала. Ответ считался правильным, если он был сделан в пределах интервала

времени 200-1000 мс после целевого стимула. Поведенческие данные включали количество пропусков целевых стимулов, количество ложных нажатий, время реакции на значимый ГО-стимул и вариация времени реакции. Промахи относились к отсутствию ответа в условии А-А, а ложные нажатия — к неправильному ответу в условии А-Р.

Также изучались аналогичные параметры когнитивных функций для групп ОКР, количество ошибок, время реакции на значимый ГО-стимул, вариация времени реакции. Эти параметры качества прохождения теста были использованы для последующей классификации при помощи алгоритмов машинного обучения.

## Описание алгоритма

### 1.1 Формализация задачи классификации

Наука, способная извлекать закономерности из ограниченного числа примеров и изучающая подобные зависимости называется машинным обучением. В области машинного обучения существуют методы, которые позволяют обрабатывать различные данные и классифицировать их. Для построения классификационных моделей в данной работе была рассмотрена задача бинарной классификации, которая является подвидом задачи *обучения с учителем (supervised learning)*. В постановке такого рода задач рассматривается *пространство объектов*  $\mathcal{X}$ , т.н. множество всех возможных точек, для каждого из которых определяется величина, называемая *ответом* или *целевой переменной*. Множество значений такой величины называется пространством ответов  $\mathcal{Y}$ . В качестве множества объектов  $\mathcal{X}$  были рассмотрены пациенты, включающие в себя экспериментальную и контрольную группы по каждому психическому расстройству. Множество допустимых ответов  $\mathcal{Y} = \{0, 1\}$ , где 1 — метка положительного класса и 0 — метка отрицательного класса является экспериментальная и контрольная группы соответственно.

Для дальнейшего анализа была подготовлена обучающая выборка из пары «пациент–метка класса» и разработан параметризованная процедура выделения признаков. Полученная матрица «пациент–признаки»  $X \in \mathbb{R}^{\ell \times d}$  ( $\ell$  — число пациентов,  $d$  — число признаков), в которой каждая строка содержит признаковое описание одного из пациентов обучающей выборки. В настоящей работе обучающая выборка состояла на основе данных ЭЭГ, собранных специалистами из ИМЧ РАН. Финальная база после обработки и подготовки данных специалистами включала 200 пациентов, включая здоровых испытуемых, по заболеванию шизофрения, и 195 для ОКР.

Нашей задачей является построение функции  $a : \mathcal{X} \rightarrow \mathcal{Y}$ , которая для любого пациента будет предсказывать правильный ответ: есть диагноз или нет. Такую функцию будем называть *алгоритмом* или *моделью*.

В машинном обучении было изобретено большое количество семейств алгоритмов, и, на сегодняшний день для решений подобного типа задач используют алгоритмы, основанные на деревьях решений, а также линейные и метрические методы классификации. Например, в работе [17, 18] с помощью SVM и Логистической регрессии была успешно проведена классификация пациентов с СДВГ на основе независимых компонент ПСС.

## 1.2 Разработка признаков

Для применения моделей машинного обучения необходимо определить признаки, которые будут извлечены из ПСС и компонент ВП, полученных с помощью ИСА. В проведенных экспериментах выделенные признаки были объединены с поведенческими данными и пропущены через масштабирование данных.

Сигнал, состоящий из ПСС, по всем каналам и условиям был разбит на пересекающиеся временные окна, как в [19]. В каждом временном окне были найдены минимальное, максимальное и среднее значения. Кроме того, для каждого сигнала вычислялись глобальное среднее, глобальный максимум и глобальный минимум, а также номера окон, в которых были достигнуты эти величины. Поскольку все характеристики окна зависят от размера окна и от сдвига между окнами, процесс извлечения признаков становится параметризованным. Эти параметры выбираются независимо для каждого условия, как и гиперпараметры модели, специфичные для каждого отдельно рассматриваемого алгоритма. Их выбор будет описан в разделе 5.1 настоящей работы.

Суммарное число признаков может получиться довольно большим в зависимости от выбранных параметров окон и может достигать 1443 признаков для рассматриваемого набора параметров. В целях борьбы с переобучением и снижения скорости обучения были рассмотрены следующие методы отбора признаков:

1. Последовательный отбор признаков (Sequential Feature Selection), при котором модель обучается на полном наборе признаков, после чего признаки исключаются по некоторому алгоритму, более подробно описанном в разделе 5.
2. Усеченный SVD, который выполняет линейное сокращение размерности. Количество оставляемых признаков рассчитывалось на основе их суммарной объясненной дисперсии.

Эксперименты показали, что усеченная SVD работает хуже для нашей задачи, в то время как последовательный отбор признаков показал улучшение значения производительности модели в большинстве случаев.

На Рис. 2 изображена блок-схема, показывающая этапы обработки данных для конкретного условия «Р-Н». В ходе эксперимента были собраны данные ПСС и поведенческие. Далее по существующему набору условий, определяющие какие сигналы и в какие промежутки времени должны быть взяты, были выбраны соответствующие сигналы по заданным интервалам для дальнейшего анализа. Впоследствии они были подвергнуты масштабированию и пропущены через этап отбора признаков, который выделяет характеристики в соответствии с параметризованной процедурой, описанной выше. Наконец, извлеченные признаки подаются на вход алгоритму классификации.

## 2. Рассматриваемые алгоритмы классификации

В последние годы в подобного рода исследованиях, где применяются результаты электроэнцефалографии, стали применяться такие алгоритмы классификации, как нейронные сети или метод опорных векторов (SVM) [13]. При использовании нелинейных классификаторов могут быть обнаружены

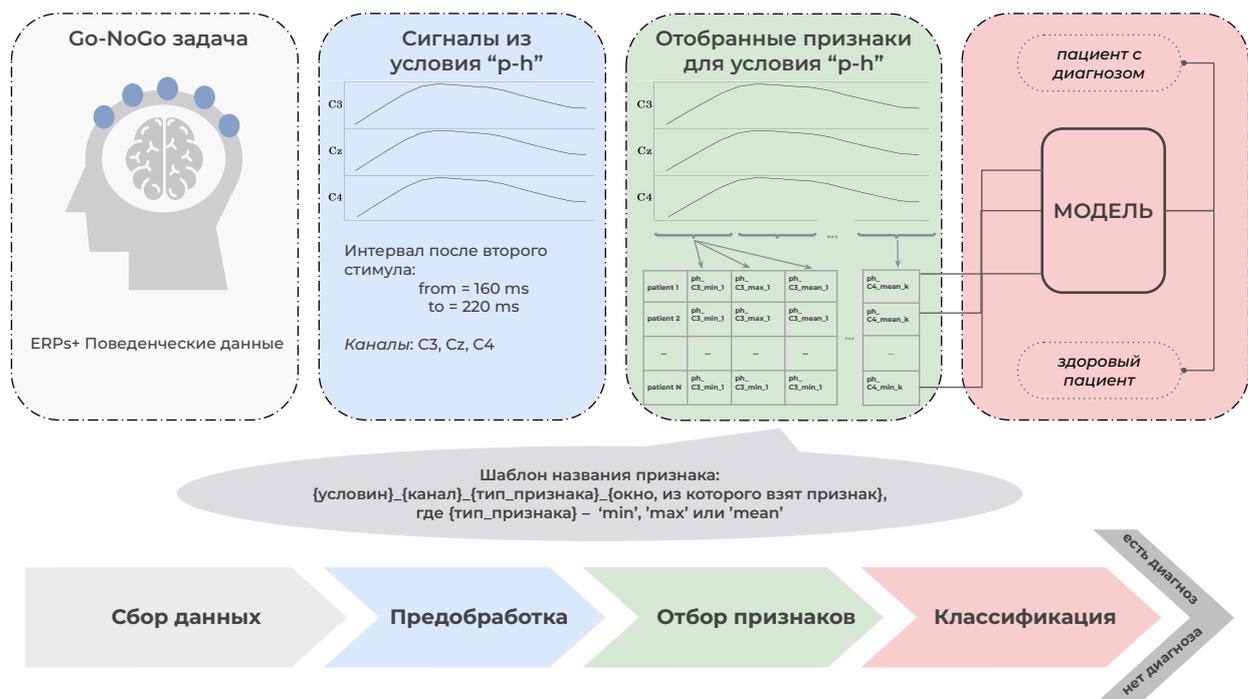


Рис. 2: Блок-схема, показывающая этапы обработки данных для состояния «P-H»

нелинейные взаимосвязи в данных, которые не являются очевидными. SVM — это метод машинного обучения, который использовался в обнаружении и удалении артефактов [8], распознавания паттернов ЭЭГ [9] и вызванных потенциалов [10, 12, 14]. Поэтому в работе применялся метод опорных векторов с различными нелинейными ядрами. Кроме того, была рассмотрена линейная модель: логистическая регрессия (LR) с регуляризацией L1/L2 из-за ее простоты и легкости интерпретации. А также алгоритм, имеющий такие преимущества, как хорошая прогностическая способность и низкие вычислительные затраты, метод k-ближайших соседей (kNN).

В ходе работы была построена стекинг-модель, которая включала в себя логистические регрессии в качестве базового классификатора, где каждая логистическая регрессия обучалась на признаках конкретного условия парадигм или на поведенческих данных. Далее модель SVM была обучена на вероятностях, полученных из логистических регрессий в качестве признаков. Параметры для всех базовых моделей и SVM были выбраны с помощью процедуры поиска оптимальных гиперпараметров по сетке, в которой задано множество гиперпараметров рассматриваемого алгоритма (*grid search*). Преимущество модели стекинга заключается в том, что мы можем анализировать важность признаков для каждого условия отдельно. Также этот подход обладает большей масштабируемостью: он позволяет добавлять больше признаков и моделей, обученных на них, без возможности переобучения других моделей. Например, можно рассматривать возможность добавления признаков, основанных на компонентах ВП, полученных методом разложения на независимые компоненты из ПСС.

### 3. Процесс обучения моделей

Поскольку классы во всей выборке не сбалансированы (132 человека в контрольной группе против 68 человек в экспериментальной группе для шизофрении; 132 человека в контрольной группе против 63 человек в экспериментальной группе для ОКР), для всех моделей было применено взвешивание классов. Кроме взвешивания классов, для сравнения использовалась функция потерь со взвешиванием классов и балансировка с помощью метода *upsampling data*. Этот метод увеличивает количество наименьших классов до обучения модели, а именно проводит дублирование  $n$  раз наименьшего класса, тем самым решая проблему несбалансированности данных — отношение количества преобладающего класса (экспериментальная группа) к менее численному (контрольной группа). Полученные результаты примерно эквивалентны, поэтому в разделе 5.1, посвященном оценке производительности моделей, разделения между этими подходами производиться не будет.

Представленные алгоритмы классификации позволяют классифицировать данные на основе заданного набора признаков. В данном исследовании параметры всего процесса обучения состоят из нескольких гиперпараметров: параметры модуля извлечения признаков (размер окна и сдвиг между окнами), параметры масштабирования данных (какой метод масштабирования использовать) и гиперпараметры, характерные для конкретной модели. Для поиска оптимальных гиперпараметров была применена процедура поиска по сетке (*grid search*) с помощью модуля GridSearchCV (из библиотеки *sklearn*<sup>1</sup>) на заранее заданном для каждого алгоритма множестве гиперпараметров. Эта техника настройки является стандартной в машинном обучении, её целью является вычисление оптимальных значений параметров путем итераций по заданной сетке всех возможных комбинаций параметров и обучения модели на их основе. Оптимальные параметры определяются как параметры, которые приводят к лучшим значениям метрик. Однако количество извлеченных признаков для каждой полученной модели на основе различных временных окон может быть очень велико и есть риск переобучения модели. Для выбора подходящего набора признаков необходимо учитывать прогностическую способность полученного классификатора. Одним из часто применяемых методов оценки того, насколько результаты статистического анализа будут обобщены на независимый набор данных, является перекрестная проверка или кросс-валидация (англ. Cross-Validation) [2]. Её основная идея заключается в том, чтобы разделить данные на  $k$  раз для оценки эффективности каждого классификатора:  $k-1$  часть данных используется для обучения каждого классификатора, а оставшаяся часть - для проверки обобщающей способности.

Система выполняла 10-кратную кросс-валидацию, с помощью которой были определены лучшие параметры. На каждом шаге подбора оптимальный гиперпараметров с помощью *grid search* после извлечения и масштабирования признаков в соответствии с текущим набором параметров выполняется необязательный этап отбора признаков перед тем, как подаваться на вход модели. Схема получения оптимального набора признаков и соответствующий им классификатор определяется схемой обратного отбора, где из набора  $N$  возможных признаков итеративным способом выбираются  $M$  лучших путём удаления пока не наступит момент, когда измеряемое качество классификатора не перестанет ухудшаться. Как видно из результатов эксперимента, отбор признаков улучшает производительность модели в большинстве случаев. Последовательный отбор признаков проводился на дополнительной

---

<sup>1</sup> <https://scikit-learn.org/stable/>

кросс-валидации, то есть обучающее текущее множество было еще раз разбито для поиска оптимального набора признаков.

Все модели были обучены на языке Python с помощью пакета *sklearn* [21].

#### 4. Метрики для оценки качества моделей

В задачах классификации одним из наиболее полных методов оценить работу построенных моделей является матрица ошибок (Рис. 3), которая состоит из 4 показателей. Столбцы такой матрицы соответствуют фактическим классам, а строки — прогнозам алгоритма.

Actual Values	norm	<b>TN</b> True Negative	<b>FP</b> False Positive
	diseased	<b>FN</b> False Negative	<b>TP</b> True Positive
		norm	diseased
		Predicted Values	

Рис. 3: Матрица ошибок

В таком случае:

1. True Positive (TP) — верно классифицированные пациенты, имеющие диагноз.
2. True Negative (TN) — верно классифицированные пациенты, не имеющие диагноз.
3. False Positive (FP) — неправильно классифицированные пациенты, имеющие диагноз (ложноположительные примеры).
4. False Negative (FN) — неправильно классифицированные пациенты, не имеющие диагноз (ложноотрицательные примеры).

На основе матрицы ошибок были посчитаны следующие метрики, отражающие качество построенных моделей:

- $Sensitivity = \frac{TP}{TP + FN}$
- $Specificity = \frac{TN}{TN + FP}$
- $Balanced\ Accuracy = \frac{(Sensitivity + Specificity)}{2}$

- $F1 = \frac{TP}{TP + \frac{1}{2}(FP + FN)}$
- $MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP) * (TP + FN) * (TN + FP) * (TN + FN)}}$

Для оценки работы бинарных классификаторов на основе показателей матрицы ошибок можно использовать несколько статистических показателей, выбор которых зависит от цели исследования. Точность (Accuracy) и F-мера, вычисляемые по матрицам ошибок, были (и остаются) одними из самых распространенных метрик в задачах бинарной классификации. Однако эти статистические показатели могут демонстрировать слишком оптимистичную оценку обобщающей способности моделей, особенно на несбалансированных данных [15, 5, 3, 1].

В [?] было показано, что коэффициент корреляции Мэтьюса (Matthews correlation coefficient, MCC) является более надежным статистическим показателем, который имеет высокое значение только в том случае, если бинарный классификатор смог правильно предсказать большинство положительных экземпляров данных и большинство отрицательных экземпляров данных. MCC колеблется в интервале  $[-1, +1]$ , причем крайние значения достигаются в случае абсолютно неправильной классификации и совершенно правильной соответственно, в то время как значение MCC равное нулю является ожидаемым значением для классификатора, подбрасывающего монету.

Основными метриками, представляющими для нас интерес в данной работе, являются чувствительность и специфичность. Чувствительность — это коэффициент истинных положительных результатов (TRP), который представляет собой долю пациентов с диагнозом, правильно идентифицированных моделью как пациенты с диагнозом. Специфичность — это истинно негативный показатель (TNR), который показывает соотношение здоровых людей к людям, которые были классифицированы как здоровые. Пороги вероятности или т.н. порог принятия решений для всех моделей были выбраны таким образом, чтобы чувствительность и специфичность были примерно одинаковыми, ввиду чего интерес представляла сбалансированная точность, которая является некоторым компромиссом между чувствительностью и специфичностью. Порог принятия решений используется, когда нужно определить, к какому классу отнести субъекта. Можно выбрать лучший результат из вывода функции принятия решения и установить его в качестве порогового значения решения и рассмотреть все те значения оценки решения, которые меньше этого порогового значения решения, как отрицательный класс (контрольная группа) и все те значения оценки решения, которые больше этого порогового значения решения, как положительный класс (экспериментальная группа). Площадь под ROC-кривой (ROC AUC) - это еще одна метрика, которую мы использовали и которая не зависит от порога вероятности.

## Результаты исследования

### Метрики производительности построенных моделей

Все рассматриваемые метрики были усреднены между 10 тестовыми множествами данных, подсчитанных в ходе кросс-валидации с целью получения более точной оценки прогностической способности построенных моделей. Каждая модель имеет свой собственный набор признаков, поскольку количество признаков зависит от выбранных параметров оконного модуля извлечения признаков и от применения последовательного отбора признаков (Sequential Feature Selection, SFS) во время процедуры *grid search*.

Sequential Feature Selection является подходом к поиску оптимального подмножества признаков, обеспечивающих наилучшую производительность модели. Последовательный отбор признаков может осуществляться прямым проходом, когда мы начинаем процесс обучения без признаков и добавляем их последовательно один за другим, и обратным проходом, когда мы начинаем обучение с полным набором признаков и исключаем их один за другим. Последний подвид метода, который итеративным способом удаляет признак один за другим пока производительность модели не начнет ухудшаться, является универсальным и именно он был использован в дальнейшем в применении к моделям. Введём для данного итеративного процесса обозначение "SFS" .

В таблице 2 приведены значения метрик чувствительности и специфичности для моделей, описанных в предыдущем разделе, полученных на данных ПСС по заболеванию шизофрения. Для каждой метрики в таблице есть два значения: среднее значение этой метрики по подмножествам кросс-валидации и ее стандартное отклонение по этим подмножествам. Слово "behavior" в скобках после названия модели означает, что модель была обучена на комбинации признаков ПСС и поведенческих данных. В противном случае модель была обучена признаках ПСС с соответствующим обозначением "ERPs"

Таблица 2: Статистические показатели производительности построенных моделей на данных ПСС шизофрении, среднее значение +/- стандартное отклонение

Model	Sensitivity	Specificity
LR	0.848 ± 0.166	0.855 ± 0.159
LR (behaviour)	0.862 ± 0.132	0.863 ± 0.149
LR (behaviour, SFS)	0.890 ± 0.128	0.885 ± 0.099
kNN	0.833 ± 0.186	0.856 ± 0.093
kNN (behavior)	0.867 ± 0.175	0.871 ± 0.098
kNN (behavior, SFS)	0.895 ± 0.130	0.916 ± 0.054
Stacking (behavior)	0.862 ± 0.116	0.871 ± 0.118
SVM	0.893 ± 0.121	0.886 ± 0.103
SVM (SFS)	0.907 ± 0.124	0.910 ± 0.091
SVM (behaviour)	0.907 ± 0.107	0.902 ± 0.082
<b>SVM (behavior, SFS)</b>	<b>0.910 ± 0.074</b>	<b>0.908 ± 0.083</b>

Наилучшую производительность показали SVM без поведенческих данных с последовательным отбором признаков и SVM с поведенческими данными с обратным последовательным отбором признаков. Модель SVM (поведение, SFSB), опишем подробнее. Данная модель имеет RBF ядро с коэффициентом  $\gamma$ , масштабируемым как  $\frac{1}{(d * V)}$ , где  $V$  - дисперсия признаков. В качестве квадратичного штрафа был

выбран L2 регуляризатор с коэффициентом  $\frac{1}{3}$  (C — обратно пропорционально регуляризации L2). Все параметры подбирались с помощью описанной ранее процедуры *grid search*. Признаки стандартизировались путем удаления медианы и масштабирования в соответствии с квантильным диапазоном по формуле:  $X_{scale} = \frac{x_i - x_{med}}{x_{75} - x_{25}}$ . Параметры окна для различных условий представлены в таблице 3.

Таблица 3: Параметры окна SVM (behaviour, SFS), шизофрения

Условие	Размер окна, мс	Размер сдвига, мс
plus 1	49	50
plus 2	5	50
NOGO	49	100
GO	20	100
P-H	5	100

Из выше полученных результатов метод опорных векторов показал наиболее высокие значения метрик. Следующим этапом было применить этот алгоритм классификации к компонентам ВП, полученных в ходе применения ИСА. Признаки, полученные на таких данных, будут обозначены через аббревиатуру "ИСА". Психиатрические заболевания, рассмотренные в данной работе, аналогично имеют обозначения: SCH — шизофрения, OCD — обсессивно-компульсивное расстройство. В таблице 4 продемонстрированы статистические показатели для соответствующих психических расстройств по всем предоставленным данным. Во всех экспериментах был подобран порог, при котором значение сбалансированной точности было максимальным.

С помощью порога принятия решений были сбалансированы основные метрики для данной задачи, чувствительность и специфичность. Наилучшие результаты показали модели, обученные на ИСА-признаках, по каждому заболеванию.

## Интерпретация результатов

Использование методов машинного обучения в задачах медицинской направленности требует гарантии отсутствия ошибок в конечной построенной модели и, тем самым, доверия результату.

Одним из недостатков нелинейных моделей является сложность их интерпретации. Если решения о важности признаков в линейных моделях можно принять, посмотрев на их коэффициенты, то для нелинейных моделей этот вопрос требует изучения альтернативных подходов. Одним из существующих способов добавить интерпретацию к модели является метод SHAP (Shapley Additive Explanations) [?]. Для расчета SHAP была использована библиотека shap Python [16].

Метод SHAP позволяет рассчитать глобальную дисперсионную значимость по каждому признаку. На Рис. 4 представлены 15 наиболее важных признаков модели SVM (behavior, SFS), построенная на данных ПСС для заболевания ОКР. Признаки по оси Y упорядочены по убыванию их важности. По оси X показано среднее абсолютное значение SHAP. Способ вычисления значений Shapley: это среднее значение предельных вкладов во все перестановки. Названия признаков ПСС представлены по шаблону 'условие' 'канал' 'тип признака' 'количество окон, если применимо', где 'тип признака' — min/max/mean. Таким образом, был проведен анализ степени влияния признаков на прогноз модели.

Таблица 4: Статистические показатели на различных данных, среднее значение и в скобках указано стандартное отклонение

Data	Sensitivity	Specificity	F1	AUC	MCC	BA
ERPs SCH (SFSB)	0.907 (0.124)	0.969 (0.051)	0.921 (0.108)	0.950 (0.059)	0.890 (0.121)	0.938 (0.069)
ERPs SCH (behavior, SFSB)	0.910 (0.074)	0.977 (0.049)	0.932 (0.065)	0.964 (0.037)	0.901 (0.101)	0.943 (0.051)
ERPs OCD (SFSB)	0.876 (0.117)	0.864 (0.089)	0.814 (0.110)	0.877 (0.095)	0.722 (0.168)	0.870 (0.083)
ERPs OCD (behavior, SFSB)	0.829 (0.129)	0.863 (0.083)	0.784 (0.100)	0.881 (0.085)	0.681 (0.152)	0.846 (0.078)
ICA SCH (SFSB)	0.967 (0.067)	0.962 (0.052)	0.949 (0.044)	0.983 (0.019)	0.927 (0.064)	0.964 (0.034)
<b>ICA SCH</b> ( behavior, SFSB)	<b>0.967</b> <b>(0.067)</b>	<b>0.977</b> <b>(0.034)</b>	<b>0.961</b> <b>(0.054)</b>	<b>0.984</b> <b>(0.024)</b>	<b>0.944</b> <b>(0.077)</b>	<b>0.972</b> <b>(0.040)</b>
ICA OCD (SFSB)	0.821 ( 0.186)	0.825 (0.109)	0.753 (0.151)	0.901 (0.094)	0.633 (0.239)	0.823 (0.031)
<b>ICA OCD</b> (behavior, SFSB)	<b>0.886</b> <b>(0.129)</b>	<b>0.963</b> <b>(0.051)</b>	<b>0.900</b> <b>(0.081)</b>	<b>0.941</b> <b>(0.074)</b>	<b>0.864</b> <b>(0.110)</b>	<b>0.924</b> <b>(0.066)</b>

Помимо абсолютных значений важности признаков интерес представляет анализ направления, в котором каждый признак оказывает влияние. Такая визуализация представлена на рисунке 5.

По оси  $Y$  аналогично показаны 15 признаков, отсортированных по степени важности, по оси  $X$  — значения SHAP. Значения справа от центральной вертикальной линии на оси  $X$  представляют класс психозов, а значения слева — здоровых людей. Красный цвет означает более высокое значение признака, синий — меньшее значение. Ширина линий определяет количество точек наблюдения. Каждая точка на графике — это одно значение SHAP для прогноза и признака. Соответственно, чем краснее точки на графике, тем выше значения признака в ней, а чем толще линия на графике, тем больше таких точек наблюдения. Тем самым, было получено общее представление о влиянии направленности признаков на основе распределения красных и синих точек. Например, высокое значение минимума в канале Fz условия NOGO\_2 более характерно для здоровых людей, в то время как меньшее значение минимума канала T5 для парадигмы 'plus1' увеличивает вероятность диагноза ОКР. Результаты полностью совпадают с ожиданиями специалистов в физиологии.

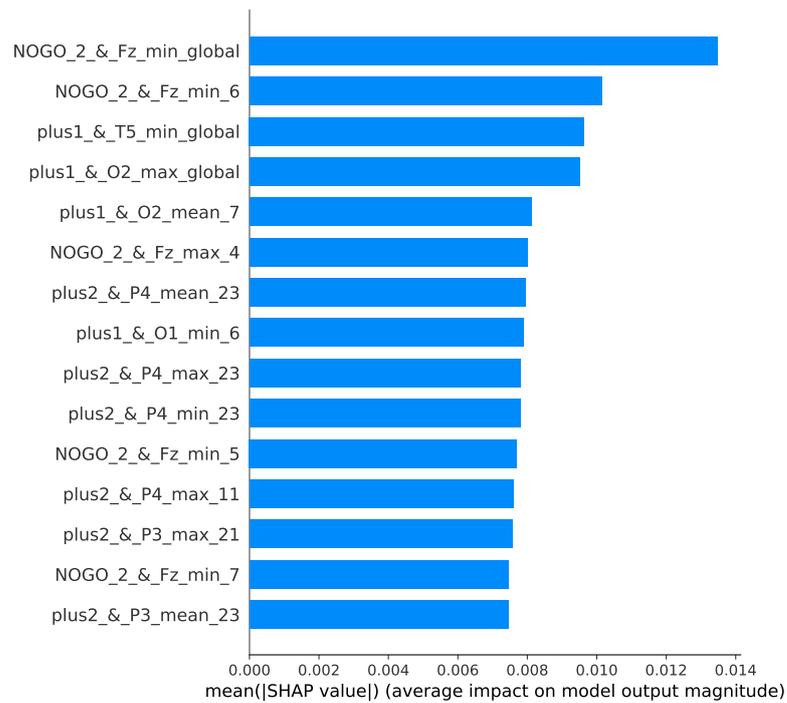


Рис. 4: Глобальная интерпретация признаков

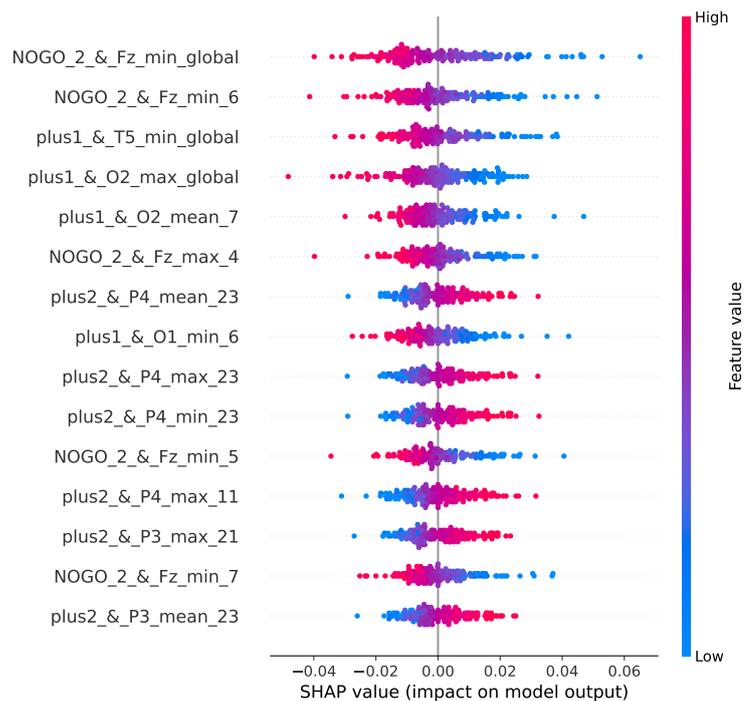


Рис. 5: Направленность влияния признаков

## Доверительные интервалы производительности моделей

Следующим этапом настоящего исследования было построить для основной метрики доверительный интервал, чтобы понять насколько полученный результат оценен правильно. Будем рассматривать статистический показатель, являющийся средним арифметическим чувствительности и специфично-

сти, сбалансированную точность (Balanced Accuracy).

Для того, чтобы найти в каких границах с заданной надежностью в 95%, следует прежде всего для всех моделей скорректировать порог принятия решения. Будем использовать метод бутстрап (семплирование с возвращением). В нашей реализации по умолчанию количество бутстрап выборок рассчитывалось автоматически исходя из желаемого уровня уверенности, равному 95%, чтобы соответствовать рекомендации, данных в статье [20], о том, чтобы иметь минимальное количество результатов, полученных методом бутстрапа, в нашем случае, оценок в каждом хвосте распределения. (На самом деле эта рекомендация относится к значениям p-value и, следовательно, к областям принятия статистических гипотез, но доверительные интервалы довольно похожи на них, чтобы использовать это правило как эмпирическое). Хотя эти авторы рекомендуют минимум 10 оценок в хвосте, R. Davidson and J. MacKinnon в работе [22] рекомендуют не менее 399 бутстрап выборок для 95% уверенности, что предполагает 11 бутстрап выборок в хвосте, поэтому мы используем эту более консервативную рекомендацию.

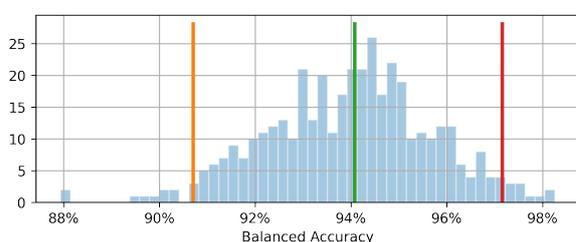


Рис. 6: ERPs данные (шизофрения)

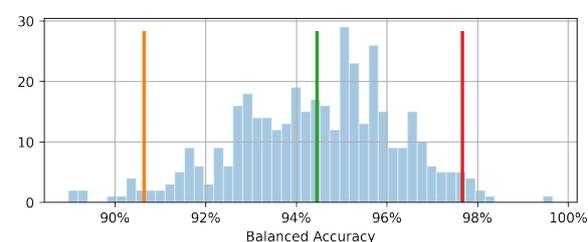


Рис. 7: ERPs данные + behavior (шизофрения)

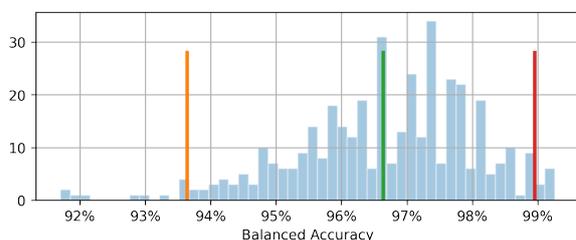


Рис. 8: ICA данные (шизофрения)

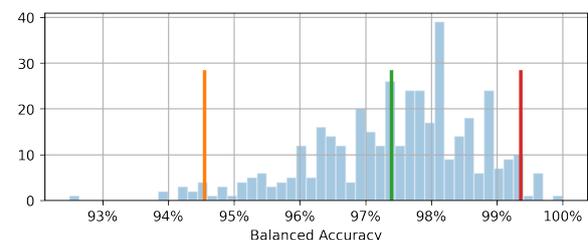


Рис. 9: ICA данные + behavior (шизофрения)

Рис. 10: Гистрограммы 401 бутстрап выборок, показывающие 95% доверительный интервал для построенных моделей по заболеванию шизофрения. Оранжевая линия показывает нижнюю границу доверительного интервала сбалансированной точности, зеленая - исходную сбалансированную точность (точечная оценка), а красная - верхнюю границу

Исходя из рекомендаций, данных в статье [22], количество сгенерированных выборок было выбрано 401 штук. Каждая из них такого же размера, что и исходный набор данных. Для каждой из них строится оценка сбалансированной точности, далее все оценки усредняются. Ввиду того, что выборка много, можем построить функцию распределения оценок, далее посчитать квантиль и вычислить доверительный интервал, т.е. доверительный интервал строится таким образом: берем квантиль из множества полученных оценок, сортируем их и получим доверительные интервалы для каждой построенной модели, изображенные на Рис. 10. Аналогичные эксперименты были проведены по заболеванию ОКР, о результатах которых будут впоследствии статьи.

Таким образом, рассчитав доверительные интервалы интересующей метрики, было наглядно пока-

зано, насколько точно тестовые данные позволили измерить производительность построенных моделей.

## Классификация по сырым сигналам ЭЭГ с помощью методов глубокого обучения: свёрточные и рекуррентные нейронные сети

### LSTM: архитектура и принцип работы построенной модели

Предложенная модель классификации временных последовательностей основана на архитектуре LSTM (Long Short-Term Memory), предназначенной для извлечения временных зависимостей и закономерностей из последовательных данных. Детальное описание работы модели представлено на Рис. 11.

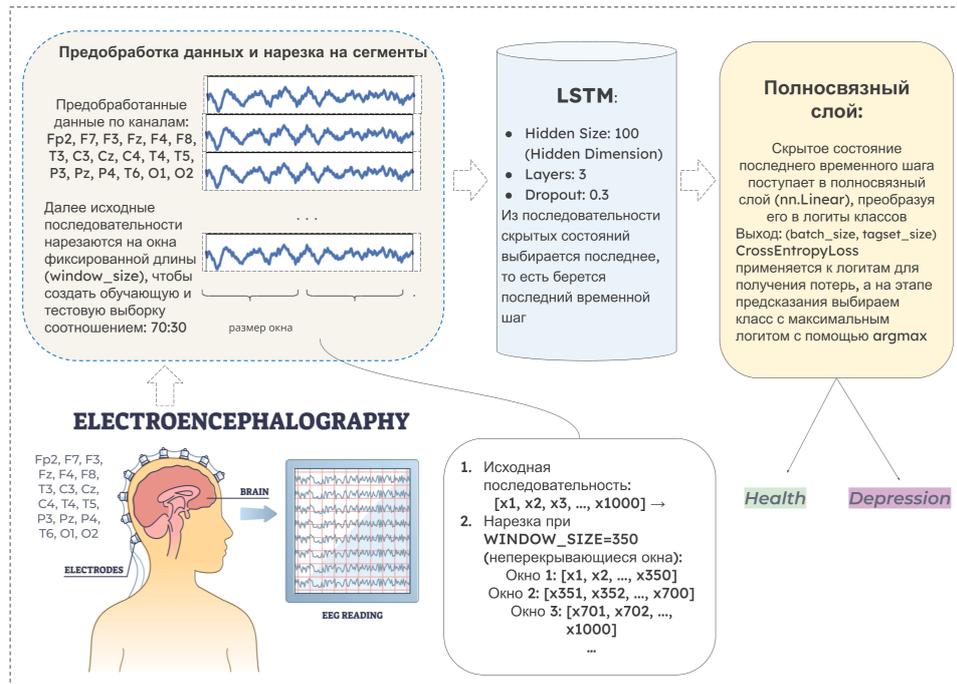


Рис. 11: Архитектура модели LSTM для классификации ЭЭГ последовательностей

Процесс работы модели включает несколько этапов, начиная с подготовки данных. Для эффективной работы модели данные проходят этап предварительной обработки, включая нормализацию значений в диапазоне  $[0, 1]$  или стандартизацию с нулевым средним и единичным стандартным отклонением. Временные ряды нарезаются на окна фиксированной длины (350 семплов), которые затем подаются в модель. Подготовленные данные поступают в трехслойную LSTM-архитектуру с размером скрытого состояния, равным 100, где LSTM извлекает временные зависимости из последовательностей. На выходе LSTM мы получаем последовательность скрытых состояний для каждого временного шага с размерностью  $(seq\_len, batch\_size, hidden\_dim)$ , например  $(350, 32, 100)$ , что позволяет обрабатывать данные пакетами (batch) и эффективно обновлять параметры модели. Из скрытого состояния последнего временного шага извлекаются высокоразмерные признаки, которые передаются в полносвязный слой для классификации, преобразуя эти признаки в итоговые предсказания классов. Для оптимизации модели используется функция потерь CrossEntropyLoss, которая включает Softmax для преобразования логитов в вероятности классов, которые затем сравниваются с истинными метками,

и на основе ошибки обновляются веса модели. На этапе предсказания для каждого окна вычисляются логиты, и с помощью операции `argmax` выбирается индекс с максимальным значением логитов, соответствующий наиболее вероятному классу. Каждое окно относится к определённому человеку, поэтому предсказания для окон агрегируются по каждому индивидууму. Итоговый класс для каждого человека определяется путём усреднения предсказанных классов всех его окон, и если среднее значение предсказаний превышает пороговое значение (например, 0.55), то человек классифицируется как "шизофрения в противном случае — как "норма". Для оценки точности классификации используется метрика *Balanced Accuracy*, которая учитывает дисбаланс классов и оценивает точность предсказаний для каждого класса отдельно. Итоговая точность классификации модели составила 81,1%. Таким образом, процесс работы модели включает этапы подготовки данных, извлечения временных зависимостей с помощью LSTM, классификацию с использованием полносвязного слоя, агрегацию предсказаний по людям и вычисление итоговой точности с помощью метрики *Balanced Accuracy*.

### CNN: архитектура и принцип работы построенной модели

Следующим этапом мы обсудим ансамблевый подход в архитектуре сверточных нейронных сетей (CNN) для анализа многоканальных данных ЭЭГ с целью диагностики депрессии. Схема ансамблевого подхода показана на рисунке 12. В этом подходе используется стратегия независимой обработки каждого канала ЭЭГ сигнала.

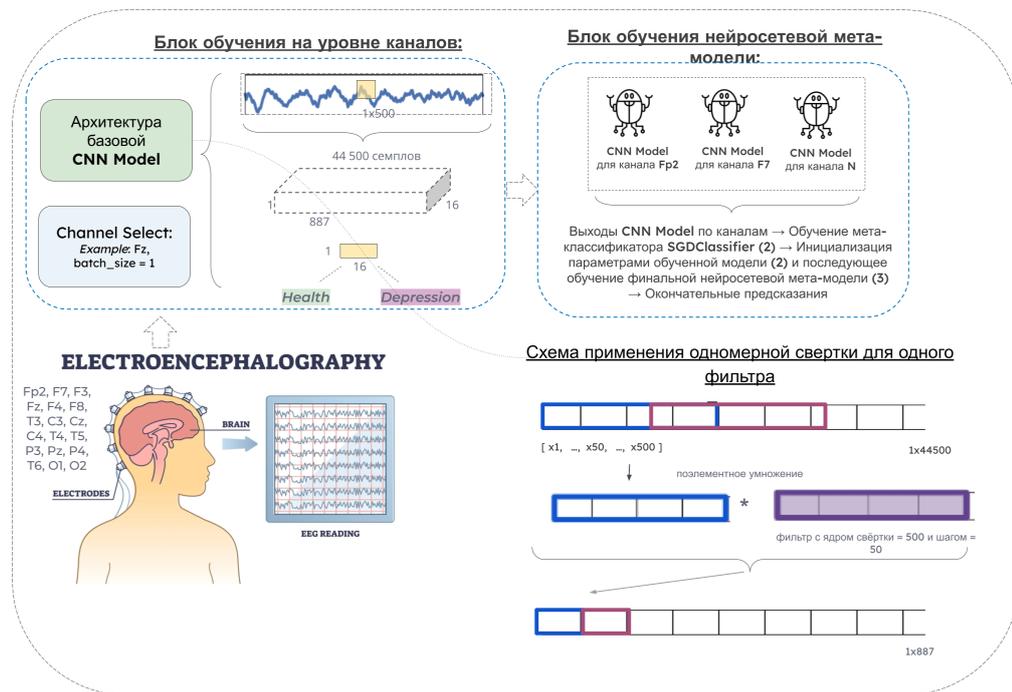


Рис. 12: Архитектура модели CNN для классификации ЭЭГ последовательностей

На первом этапе для каждого канала обучается отдельная сверточная нейронная сеть (CNN), которая извлекает важные признаки из сырых ЭЭГ сигналов. Архитектура простой сверточной сети состоит из нескольких этапов, каждый из которых выполняет определённую операцию для извлечения признаков. Рассмотрим пример обработки одного канала ЭЭГ сигнала. Входные данные представляют

собой одномерный временной ряд с размерностью  $(1, 44500)$ , где 1 — это количество каналов, а 44500 — длина последовательности (в миллисекундах). В первом сверточном слое ('Conv1D') используются 16 фильтров с ядром размером 500, шагом 50 и паддингом 1, что сокращает длину временной последовательности до 887 и приводит к размерности  $(1, 887, 16)$ , где 16 — это количество каналов (фильтров). Затем к выходу применяется функция активации ReLU, оставляя размерность неизменной, но добавляя нелинейность.

Для уменьшения размерности и получения глобального представления временного ряда используется слой 'AdaptiveAvgPool1d(1)', который усредняет значения по временной оси, сокращая размерность до  $(1, 1, 16)$ . Затем данные преобразуются в двумерный вид с помощью выравнивания ('Flatten'), что приводит к форме  $(1, 16)$ . Наконец, полносвязный слой ('Linear') снижает размерность до  $(1, 2)$ , создавая итоговый выход с предсказаниями для двух классов.

Таблица 5: Архитектура нейронной сети

Этап	Описание	Размер выходного тензора
<b>Вход</b>	Размер батча 1, 1 канал, длина 44500	$(1, 1, 44500)$
<b>Сверточный слой (Conv1D)</b>	16 фильтров, ядро 500, шаг 50, паддинг 1	$(1, 16, 887)$
<b>Активация ReLU</b>	Применяет активацию ReLU	$(1, 16, 887)$
<b>AdaptiveAvgPool1d</b>	Уменьшает до 1 временного шага	$(1, 16, 1)$
<b>Выравнивание (Flatten)</b>	Преобразует выход в двумерный вид	$(1, 16)$
<b>Полносвязный слой (Linear)</b>	Полносвязный слой, снижает до 2 классов	$(1, 2)$
<b>Выход</b>	Итоговый выход с предсказаниями для 2 классов	$(1, 2)$

name_channel	Balanced Accuracy
C3	0.825
C4	0.787
Cz	0.818
F3	0.781
F4	0.791
F7	0.819
F8	0.777
Fp2	0.803
Fz	0.811
O1	0.834
O2	0.826
P3	0.843
P4	0.774
Pz	0.812
T3	0.769
T4	0.798
T5	0.810
T6	0.785

Таблица 6: Усредненные значения по фолдам сбалансированной точности для каждого канала

В Табл. 6 представлены результаты классификации по отдельным каналам ЭЭГ. Для каждого канала, например, C3, C4, Cz, F3 и других, указана сбалансированная точность. Эти значения демонстрируют производительность модели на каждом канале в задаче классификации депрессии. Как видно, точность варьируется от 0.774 (для канала P4) до 0.843 (для канала P3), что указывает на разнообразие производительности модели в зависимости от канала.

После того как предсказания, сделанные каждой моделью CNN для отдельного канала, получены,

они объединяются и передаются в мета-классификатор. Мета-классификатор, использующий метод стохастического градиентного спуска (SGD), адаптирует веса каналов, чтобы объединить результаты в одно обобщённое предсказание. Это позволяет модели учитывать вклад каждого канала в итоговое решение. Тем самым, ансамблевый подход к анализу многоканальных данных ЭЭГ предлагает уникальную стратегию обработки каналов для повышения точности и устойчивости классификации. Архитектура данной модели включает в себя набор отдельных сверточных нейронных сетей (CNN), обучаемых для каждого канала данных, и мета-классификатор, который объединяет их выходы. Этот подход учитывает различную информативность каналов, обеспечивая их независимую обработку и последующее агрегирование предсказаний. Представленный полный процесс обучения ансамбля с описанием архитектуры и этапов обработки данных, а также преимуществ использования предлагаемого метода.

— Этап 1: Обучение отдельных моделей для каждого канала

На первом этапе проводится обучение отдельных моделей, предназначенных для обработки сигналов каждого канала ЭЭГ отдельно. Данные предварительно нормализуются и фильтруются для минимизации шума и удаления артефактов. Это позволяет структурировать сигналы в виде временных серий, которые подаются на вход отдельной CNN. Для каждого канала строится модель с фиксированными гиперпараметрами, включая количество сверточных слоев, число фильтров, функции активации и параметры регуляризации. Эти CNN обучаются на данных одного канала, чтобы каждая модель могла лучше захватывать специфическую информацию, содержащуюся в этом канале, и минимизировать влияние перекрестных помех между каналами. После завершения этого этапа каждая модель выдает предсказания на основе только одного канала.

— Этап 2: Обучение мета-классификатора с использованием стохастического градиентного спуска (SGD)

На втором этапе предсказания от всех каналов объединяются, формируя новый набор признаков для мета-классификации. Эти предсказания от CNN, обученных на отдельных каналах, используются в качестве входных данных для мета-классификатора, который обучается с помощью метода стохастического градиентного спуска (SGD). Для настройки гиперпараметров и оптимизации метрик, таких как F1, сбалансированная точность и площадь под ROC-кривой (AUC), используется процедура перекрестной проверки, например, KFold. Этот мета-классификатор служит для агрегирования информации, поступающей от отдельных моделей по каналам, и позволяет учитывать весовой вклад каждого канала в общей задаче классификации, адаптируя модель к различной информативности сигналов.

— Этап 3: Инициализация и обучение финальной мета-модели

На заключительном этапе создается финальная нейросеть, инициализируемая весами, полученными из обученного мета-классификатора SGD. Эта сеть служит мета-моделью, принимающей выходные предсказания всех отдельных моделей по каналам и объединяющей их через полностью связанный слой. После инициализации весов финальная мета-модель дообучается на выходах отдельных CNN, представляющих каждый канал. В процессе обучения используются метод ранней остановки и оптимизаторы, такие как Adam или SGD, для минимизации ошибки и повышения точности модели. Это позволяет мета-модели эффективно интегрировать информацию от всех каналов, создавая обобщенное

предсказание с учетом особенностей сигналов каждого канала.

**Полученные результаты и выводы:** в итоге, сбалансированная точность для мета-классификатора, использующего метод стохастического градиентного спуска (SGD), составляет 0.940, а для нейросетевой мета-модели удалось достичь значение метрики еще лучше — 0.947 сбалансированной точности, что подтверждает эффективность использования нейронных сетей для агрегирования предсказаний с различных каналов. Нейронная мета-модель имеет также важное преимущество в скорости выполнения предсказаний. Она эффективно работает на GPU, обеспечивая параллельную обработку данных и быструю классификацию.

Ансамблевый подход с отдельной обработкой каналов и последующим объединением предсказаний через мета-классификатор доказал свою эффективность для задач классификации многоканальных ЭЭГ-данных. Индивидуальная обработка каналов помогает учитывать уникальную информативность каждого сигнала, а использование мета-классификатора позволяет эффективно агрегировать полученные предсказания. Данный метод улучшает общую точность и устойчивость модели, а также позволяет адаптироваться к особенностям каждого канала, минимизируя перекрестные помехи. В перспективе данная модель может быть усовершенствована за счет использования более сложных нейронных сетей и методов ансамблирования, а также более гибкой настройки гиперпараметров, что расширяет ее применимость к задачам анализа многоканальных биосигналов, таких как классификация психических состояний или распознавание событий на основе данных ЭЭГ.

## Заключение

Психиатрические заболевания значительно снижают качество жизни людей. Своевременно начатое лечение чрезвычайно важно для смягчения долгосрочных негативных последствий. В данном проекте приведены новый подход к диагностике заболеваний шизофрения и обсессивно-компульсивное расстройство (ОКР) с помощью методов машинного обучения. В качестве одного из подходов к анализу неинвазивных ЭЭГ сигналов был использован анализ вызванных потенциалов. Данные включали потенциалы, связанными с событиями (ПСС), полученных по данным ЭЭГ больных и здоровых людей, выполняющих модификацию визуальной задачи Go/NoGo парадигм, а также компоненты вызванных потенциалов, полученных методом разложения на независимые компоненты (ICA).

Для применения моделей машинного обучения из данных извлекались различные признаки во временных окнах. Процесс извлечения признаков был разработан с помощью специальной параметризованной процедуры, оптимальные значения параметров которой были выбраны с помощью процедуры *Grid Search* в комбинации с гиперпараметрами модели. После извлечения признаков был применен отбор признаков (*Sequential Feature Selection*) с целью уменьшения переобучения и снижения вычислительной сложности.

На полученном наборе признаков по каждому заболеванию были обучены различные модели. Чувствительность и специфичность лучшей модели (метод опорных векторов, SVM) по заболеванию шизофрения составили 96,7% и 97,7%, по ОКР – 88,6% и 96,3% соответственно. Полученные показатели свидетельствуют о высокой точности моделей для выявления диагноза на предоставленных данных. Далее с помощью метода *SHAP* у лучшей модели были выделены наиболее значимые признаки с целью понимания факторов принятия решений моделью. Результаты были провалидированы специалистами в физиологии и полностью совпали с их ожиданиями.

Ансамблевый подход к анализу многоканальных данных ЭЭГ для диагностики депрессии использует стратегию независимой обработки каждого канала, что позволяет выделить ключевые особенности каждого сигнала. На первом этапе обучаются отдельные сверточные нейронные сети (CNN) для каждого канала. Затем предсказания этих CNN объединяются и передаются мета-классификатору, который на основе метода стохастического градиентного спуска (SGD) адаптирует веса каналов для создания обобщенного предсказания. На заключительном этапе инициализируется финальная нейронная мета-модель, которая агрегирует выходы всех CNN. Данный подход обеспечивает высокую точность классификации, достигая 94,6% сбалансированной точности.

Использование нейронной мета-модели по сравнению с простым мета-классификатором на базе SGD имеет несколько преимуществ. Нейронная сеть обладает большей гибкостью и возможностью более глубокой интеграции сигналов, что позволяет учесть нелинейные зависимости между каналами и повысить обобщающую способность модели. Кроме того, нейронная мета-модель работает быстрее при прогнозировании, так как позволяет выполнять вычисления параллельно на GPU, что делает ее эффективным и производительным инструментом для задач анализа биосигналов.

## Список литературы

1. Akosa JS. Predictive accuracy: a misleading performance measure for highly imbalanced data. In: Proceedings of the SAS Global Forum 2017 Conference. Cary, North Carolina: SAS Institute Inc.; 2017. p. 942–2017.
2. Arlot S, Celisse A: A survey of cross-validation procedures for model selection. Eprint 2009, arXiv:0907.4728.
3. Bekkar M, Djemaa HK, Alitouche TA. Evaluation measures for models assessment over imbalanced data sets. *J Informa Eng Appl.* 2013;3(10): 27–38.
4. Chapman R.M., McCrary J.W. EP component identification and measurement by principal components analysis // *Brain Cogn.* 1995. V. 27. P. 288.
5. Gu Q, Zhu L, Cai Z. Evaluation measures of the classification performance of imbalanced data sets. In: Proceedings of ISICA 2009 – the 4th International Symposium on Computational Intelligence and Intelligent Systems, Communications in Computer and Information Science, vol. 51. Heidelberg: Springer; 2009. p. 461–71.
6. Makeig S., Bell A.J., Jung T.P., Sejnowski T.J., 1996. Independent component analysis of electroencephalographic data // *Advanced in Neural Inform. Proc. Systems.* 8:145.
7. Vapnik VN: The nature of statistical learning theory. Springer, 2nd 2000.
8. Shao SY, Shen KQ, Ong CJ, Wilder-Smith EP, Li XP: Automatic EEG artifact removal: a weighted support vector machine approach with error correction. *IEEE Trans Biomed Eng* 2009, 56:336-344.
9. Li J, Zhang L, Tao D, Sun H, Zhao Q: A prior neurophysiologic knowledge free tensor-based scheme for single trial EEG classification. *IEEE Trans Neural Syst Rehabil Eng* 2009, 17:107-115.
10. Hong B, Guo F, Liu T, Gao X, Gao S: N200-speller using motion-onset visual response. *Clin Neurophysiol* 2009, 120:1658-1666.
11. Hastie T, Tibshirani R, Friedman J: The elements of statistical learning. Data mining, inference, and prediction. Springer, 2nd 2009.
12. Rakotomamonjy A, Guigue V: BCI competition III: dataset II- ensemble of SVMs for BCI P300 speller. *IEEE Trans Biomed Eng* 2008, 55:1147-1154.
13. Salvaris M, Sepulveda F: Visual modifications on the P300 speller BCI paradigm. *J Neural Eng* 2009, 6:046011.
14. Salvaris M, Sepulveda F: Visual modifications on the P300 speller BCI paradigm. *J Neural Eng* 2009, 6:046011.
15. Sokolova M, Japkowicz N, Szpakowicz S. Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation. In: Proceedings of Advances in Artificial Intelligence (AI 2006), Lecture Notes in Computer Science, vol. 4304. Heidelberg: Springer; 2006. p. 1015–21.
16. S. Lundberg and Su-In Lee (2017). A Unified Approach to IntERPsreting Model Predictions. NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, pp. 4768–4777.
17. A. Mueller, G. Candrian, J. D. Kropotov, V. A. Ponomarev, and G. M. Baschera, Classification of ADHD

- patients on the basis of independent ERP components using a machine learning system, *Nonlinear Biomed Phys*, vol. 4 Suppl 1, p. S1, Jun 3 2010.
18. Müller A, Vetsch S, Pershin I, Candrian G, Baschera GM, Kropotov JD, Kasper J, Rehim HA, Eich D. EEG/ERP-based biomarker/neuroalgorithms in adults with ADHD: Development, reliability, and application in clinical practice. *World J Biol Psychiatry*. 2020 Mar;21(3):172-182. doi: 10.1080/15622975.2019.1605198. Epub 2019 May 7. PMID: 30990349.
  19. A. Mueller, G. Candrian<sup>1</sup>, J. D. Kropotov, V. A. Ponomarev, Gian-Marco Baschera (2010). Classification of ADHD patients on the basis of independent ERPs components using a machine learning system. *Nonlinear biomedical physics*, vol. 4, Suppl 1.
  20. B. V. North, D. Curtis and P. C. Sham, Note on the Calculation of Empirical P Values from Monte Carlo Procedures, PMID: PMC379178 PMID: 12111669.
  21. Pedregosa et al. (2011). Scikit-learn: Machine Learning in Python. *JMLR* 12, pp. 2825-2830.
  22. Russell Davidson James G. MacKinnon (2000) Bootstrap tests: how many bootstraps?, *Econometric Reviews*, 19:1, 55-68, DOI: 10.1080/07474930008800459
  23. Walter W. Cooper R. A. V. Contingent Negative Variation: An Electric Sign of Sensori-Motor Association and Expectancy in the Human Brain // *Nature*. — 1964.
  24. С. А. Евдокимов , М. В. Пронина , Г. Ю. Полякова , В. А. Пономарев, Ю. И. Поляков, 2, Ю. Д. Кропотов, Анализ независимых компонент вызванных потенциалов пациентов с установленными диагнозами шизофрения, обсессивно-компульсивное расстройство и депрессивное расстройство, 2014.
  25. Поляков Ю.И., Кропотов Ю.Д., Пронина М.В., Забегаловская Ю.Ю., Коненков С.Ю., Пономарев В.А., Аничков А.Д., Точилор В.А. Особенности вызванных потенциалов у больных, страдающих обсессивно-компульсивными расстройствами и химической зависимостью. *Профилактическая и клиническая медицина*. 2011а. 39(2): 118–122.
  26. Поляков Ю.И., Кропотов Ю.Д., Пронина М.В., Пономарев В.А., Плотникова И.В., Точилор В.А. Независимые компоненты вызванных потенциалов больных шизофренией. *Профилактическая и клиническая медицина*. 2011б. 40(3): 251–255.
  27. Полякова Г.Ю., Кропотов Ю.Д., Поляков Ю.И., Пронина М.В., Пономарев В.А., Точилор В.А. Независимые компоненты когнитивных вызванных потенциалов у больных с депрессивным расстройством. *Профилактическая и клиническая медицина*. 2012. 42(1): 19–24.