



Московский Государственный Университет имени М.В.Ломоносова

Факультет вычислительной математики и кибернетики

Магистерская программа "Большие данные: инфраструктуры и
методы решения задач"

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

**Использование вспомогательных наборов данных
для доменного состязательного обучения в задаче
распознавания эмоций по электроэнцефалограмме
мозга**

Лебедева Екатерина Игоревна

Научный руководитель:

к.т.н. Ступников Сергей Александрович

Научный консультант:

Шанин Иван Андреевич

Москва, 2021

Содержание

Введение	3
Постановка задачи	8
1 Обзор известных методов и средств решения проблемы	10
1.1 Предобработка данных	10
1.2 Извлечение признаков из ЭЭГ сигнала	12
1.3 Классификация с помощью машинного обучения	17
1.4 Нейронные сети	21
1.5 Методы доменной адаптации	26
2 Исследование и построение решения	28
2.1 Общее решение задачи распознавания эмоций	28
2.2 Доменная адаптация	30
3 Описание практической части	32
3.1 Наборы данных	32
3.2 Предобработка данных	35
3.3 Сравнение обучения при разном разбиении на выборки	38
3.4 Распознавание эмоций с помощью глубокого обучения	39
3.5 Доменная адаптация	40
Заключение	43
Список литературы	44

Аннотация

Распознавание эмоций — важная и сложная задача современных вычислительных систем, взаимодействующих с человеком. Электрические импульсы нейронов мозга, зафиксированные с помощью электроэнцефалографии (ЭЭГ), являются важным источником данных с высоким временным разрешением, и имеют прямое отношение к активности человеческого мозга. Оценка эмоционального состояния на основе ЭЭГ затруднена из-за отсутствия размеченных обучающих данных и сильных зависимостей от субъекта и сеанса записи данных. Для обучения модели, которая будет устойчивой к изменению домена в данных ЭЭГ, могут применяться различные методы адаптации, но объем доступных обучающих данных все еще недостаточен. В этой работе предлагается подход, основанный на доменном состязательном обучении и комбинирующий доступный обучающий корпус с немаркированным набором данных в рамках обучения с частичным привлечением учителя. В работе представлен подробный анализ доступных наборов данных и существующих методов для задачи распознавания эмоций. Эффект снижения точности распознавания эмоций, вызванный зависимостями от субъекта и сеанса, был измерен на наборе данных DEAP, что доказывает необходимость разработки подходов, которые будут использовать большие наборы данных для получения более обобщенной модели.

Введение

В последнее время растет интерес к использованию ЭЭГ сигнала для анализа функционирования человеческого мозга. Результаты обработки ЭЭГ стали использоваться при создании интерфейсов «мозг-компьютер» и в нейрофизиологических исследованиях. Нейрокомпьютерные интерфейсы позволяют человеческому мозгу и электронному устройству (например, компьютеру) обмениваться информацией без привычных устройств ввода и/или вывода такие как мышь, клавиатура и другие. Уже существуют устройства, способные распознавать зрительные и воображаемые образы, воспринимаемые человеком [1]. Распознавание эмоций — одна из важнейших задач развития этих областей, так как способность компьютера распознавать человеческие эмоции ещё больше расширяет возможности взаимодействия человека с компьютером. В исследовательских работах по психическим расстройствам демонстрируется, что с помощью анализ сигнала ЭЭГ во время выполнения задач, действующих эмоции, можно оценить риск развития большого депрессивного расстройства [2]. Следовательно, подобные устройства могут быть использованы в медицинской отрасли в диагностических целях. Авторы работ, посвящённых аффективным взаимодействиям мозга и компьютера, считают, что распознавание эмоций по сигналу ЭЭГ позволит роботам и машинам читать интерактивные намерения и состояния людей и реагировать на человеческие эмоции [3–5]. Более того, решение проблемы распознавания эмоций может способствовать развитию нейромаркетинга для определения потребительских предпочтений [6]. И еще одна область применения задачи - это оценка рабочей нагрузки [7] и определение усталости от вождения [8].

Электроэнцефалография

Электроэнцефалография - метод исследования головного мозга с помощью регистрации разности электрических потенциалов, возникающих в процессе его жиз-

недеятельности. Получаемая запись - электроэнцефалограмма (ЭЭГ) — является суммарной электрической активностью многих миллионов нейронов. Таким образом, ЭЭГ отражает функциональную активность головного мозга. ЭЭГ запись — многоканальный непрерывный сигнал, измеряющий разницу между электрическими потенциалами, зарегистрированными в двух областях мозга. Во время этой записи электроды помещаются на поверхность кожи головы. Регистрирующие электроды располагают в определённых областях головы так, чтобы на записи были представлены все основные отделы мозга. Для улучшения проводимости кожи на контактную поверхность электродов наносится гель. Для фиксации электродов на голове используются эластичные каски. Из-за необходимости отслеживания постоянного контакта электродов с кожей головы процесс записи сигнала с помощью такого медицинского оборудования может быть длительным и трудоёмким (Рис. 1а). В последние годы на рынке появился ряд доступных потребителям энцефалографов, или ВСІ(brain-computer interface) устройств (Рис. 1б) [9–11]. Эти устройства обычно включают меньшее количество электродов, которые часто используются без проводящего геля. Это делает технологию ВСІ более дешевой и доступной. В связи с этим наблюдается тенденция к увеличению количества доступных данных.



(а) Многоканальное медицинское устройство



(б) Четырёхканальное устройство Muse

Рис. 1: Два вида устройств для записи ЭЭГ.




Рис. 2: 5 основных ритмов ЭЭГ: дельта, тета, альфа, бета, гамма.

Разные отделы мозга отвечают за разные задачи, например: лобные доли — за мышление и память, теменные — за слух. Чем сильнее возбуждаются нейроны — тем больше электрического поля они создают. Также разные процессы отражаются в разных частотных диапазонах электрической активности мозга, или «ритмах» ЭЭГ (Рис. 2). Например, альфа-ритм (от 8 до 12 Гц) преобладает при сосредоточенном внимании, а бета-активность (от 16 до 24 Гц) наблюдается во время эмоциональных и когнитивных процессах в мозге [12].

Запись ЭЭГ всегда загрязнена артефактами, такими как ЭОГ (глазная),


ЭКГ (сердечная), ЭМГ (мышечная) и шум. Следовательно, процесс анализа данных должен содержать предварительную обработку сигнала для автоматического решения этой проблемы.

В качестве возможных вариантов протокола эксперимента используются следующие системы регистрации сигналов ЭЭГ:


1. Состояния покоя с открытыми или с закрытыми глазами (resting states with eyes open – REO, with eyes closed – REC). Пациент находится в расслабленном состоянии и ни о чем не думает. Эта процедура используется для анализа общего состояния пациента. И подходит для всех, в том числе и для людей с ограниченными возможностями.
2. Связанные с событиями потенциалы (event-related potentials – ERP) [13]. В таких экспериментах компьютер посылает сигнал, представляющий стимул, на устройство, записывающее ЭЭГ, всякий раз, когда возникает стимул или реакция. Такими раздражителями могут быть периодические световые воздействия при разных значениях частоты воздействия. Сегменты данных ЭЭГ, привязанные по времени к сигналам событий, извлекаются из общего ЭЭГ сигнала и усредняются.
3. Связанные с выполнением задач. Нейронная активность записывается при выполнении различных мыслительных задач. Пациенту также следует быть расслабленным и сосредоточить его внимание только на выполнении поставленной задачи. Это могут быть такие задачи, как счёт в уме или чтение.
4. Сомнография [14]. ЭЭГ записывается во время сна. Электроэнцефалограмма сна (ЭЭГ) может быть записана для анализа стадий сна или причин недосыпания.

Эмоции

Эмоция - это психическое состояние и аффективная реакция на событие, основанная на субъективном опыте. Её трудно измерить, потому что это субъективное ощущение. Но для решения задачи их необходимо как-то оценить или классифицировать. Эмоции можно рассматривать в терминах «положительные», «отрицательные» или «нравится», «не нравится» [6]. Также можно выделить набор основных эмоций, таких как гнев, страх, печаль, отвращение, счастье, удивление [15], и попытаться решить задачу классификации. Исследователи часто используют двух- или трехмерное пространство для отображения эмоций [16; 17], где различные точки-эмоций могут быть расположены на двухмерной плоскости, состоящую из оси валентности (valence) и оси возбуждения (arousal) (Рис. 3а) или на трехмерной области с добавлением оси интенсивности (dominance) (Рис. 3б).



(a) 2D



(b) 3D

Рис. 3: Пространственное представление эмоций [18].

Постановка задачи

Современные методы решения задач классификации используют глубокие нейронные сети для обучения на тренировочных данных и дальнейшего распознавания классов входных данных. Нейронные сети требуют большого количества обучающих данных. Обычно наборы данных ЭЭГ содержат данные от небольшого числа субъектов. Это связано с тем, что для сбора данных требуются специальные устройства и правильные экспериментальные условия. Несколько наборов данных могут быть объединены, чтобы увеличить объем обучающих данных. Но каждый набор данных был собран разными устройствами, с разными протоколами экспериментов и разными стимулами. Поэтому сложно проводить обучение на данных из нескольких источников. Еще одна проблема - низкая точность прогнозов для испытуемых, данные которых не были доступны в обучающей выборке. Объем наборов данных, размеченных по классам-эмоциям, недостаточен. Но при этом существуют уже большое количество наборов данных ЭЭГ без соответствующих меток, которое могло бы быть использовано в улучшении качества определения эмоций.

Цели и задачи

Основной целью работы является исследование подходов в задаче распознавания эмоций по ЭЭГ и возможных методов снижения междоменной изменчивости данных и разработка нейросетевой архитектуры, использующей для обучения большой объём данных за счёт добавления неразмеченных данных в обучающую выборку.

Таким образом, поставлены следующие задачи:

1. Изучение работ по темам обработки и анализа ЭЭГ сигнала, распознавания эмоций по измерениям ЭЭГ, доменной адаптации.
2. Поиск и получение доступа к необходимым наборам данных.

3. Подтверждение актуальности проблемы доменной адаптации с помощью обучения классификатора с разным разбиением данных на обучающую и тестовую выборки.
4. Повторение существующего решения задачи распознавания эмоций с помощью нейросети.
5. Доработка нейросетевую архитектуру, добавив возможность обучения на размеченных данных.
6. Проверить, позволяет ли новая архитектура лучше предсказывать классы для входных данных из новых доменов.

1 Обзор известных методов и средств решения проблемы

блемы

1.1 Предобработка данных

ЭЭГ данные состоят не только из записей активности мозга, но и из ряда артефактов: компонентов сигнала, не связанных с мозговой деятельностью субъекта.

Артефакты могут быть двух видов:

1. *Физиологические* (Рис. 4). Появляются вследствие физиологических процессов организма, таких, как мышечная активность, сердцебиение, движения глаз.
2. *Физические*. Возникающие в результате технических погрешностей, таких, как сетевая наводка и погрешности измерений при загрязненных контактах.




Рис. 4: Физиологические артефакты на ЭЭГ записи

Таким образом, необходимо детектировать наличие артефакта в конкретный момент времени и очистить от него сигнал. Для этого может использоваться

процедура удаления участков записи, содержащих артефакты. Данная процедура может быть выполнена специалистами, но это требует тщательного и дорогостоящего анализа каждого образца. В обзоре [19] рассмотрены основные подходы к задаче автоматической предварительной обработки и очистки сигнала ЭЭГ. К наиболее популярным методам относятся методы регрессионного анализа, методы слепого разделения источников, канонический корреляционный анализ и методы цифровой обработки сигналов.

Многоканальный сигнал можно разложить на квазинезависимые компоненты, решив задачу слепого разделения источников (Рис. 5). Это может быть достигнуто с помощью метода независимых компонент (independent component analysis – ICA) или более современных подходов, основанных на глубоких нейронных сетях автокодировщиках. В данном методе исходя из того, что с помощью прибора измерен сигнал, и в результате измерения получены наблюдаемые переменные $X_i(t)$, предполагается, что эти переменные могут быть смоделированы как линейные комбинации скрытых переменных $S_j(t)$, которые соответствуют источнику сигнала. В результате решается задача оценки коэффициентов a_{ij} в формуле отображения $X = AS$.

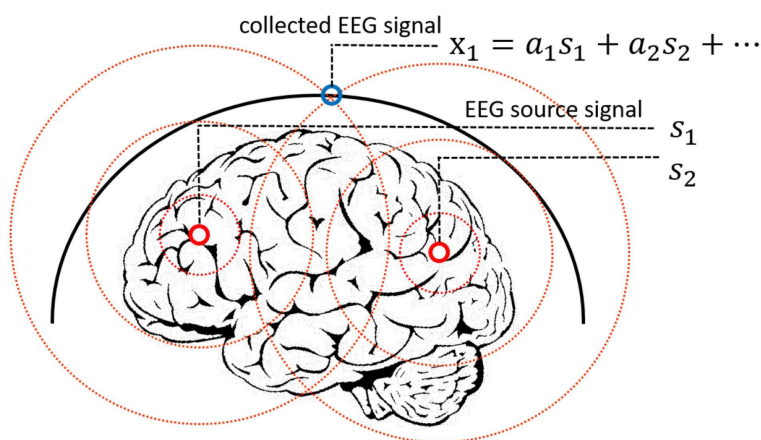


Рис. 5: Разделение источников сигнала

1.2 Извлечение признаков из ЭЭГ сигнала

Перед классификацией ЭЭГ сигнала присутствует этап извлечения признаков из данных, на основе которых будет настраиваться классификатор. На данном этапе сигнал ЭЭГ делится на короткие временные фрагменты, признаки извлекаются из каждого фрагмента и объединяются в последовательность. Разбиение на фрагменты проводится с использованием оконных функций: значения сигнала на отрезке $[t_1; t_2]$ домножаются на функцию $w(t)$, затем происходит сдвиг, и обрабатывается сигнал на отрезке $[t_1 + \Delta t; t_2 + \Delta t]$. Использование прямоугольного окна равносильно делению сигнала на фрагменты без изменения значений (Рис. 6а). Обычно оконные функции используются для сглаживания сигнала на концах отрезка, для избежания всплесков (эффект Гиббса [20]) в спектре сигнала (Рис. 6б).

Помимо фрагментации сигнала может дополнительно проводиться спектральный анализ. Для этого используется **преобразование Фурье** [21], в основе которого лежит интегральное преобразование и ряды Фурье. Преобразование Фурье позволяет представить любую функцию гильбертова пространства в виде комплексного ряда Фурье, который и называют спектральным представлением сигнала или спектром. То есть функции времени сопоставляется функция частоты, которая описывает коэффициенты (амплитуды) при разложении исходной функции на элементарные составляющие — гармонические колебания с разными частотами (Рис. 7). Преобразование Фурье функции f вещественной переменной является интегральным и задаётся следующей формулой:

$$F(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} f(x)e^{-ix\omega} dx \quad (1)$$

Непрерывное преобразование Фурье используют, как правило, в теории при рассмотрении сигналов, которые изменяются в соответствии с заданными функциями, но на практике обычно имеют дело с результатами измерений, которые представляют собой дискретные данные. Результаты измерений фиксируются через

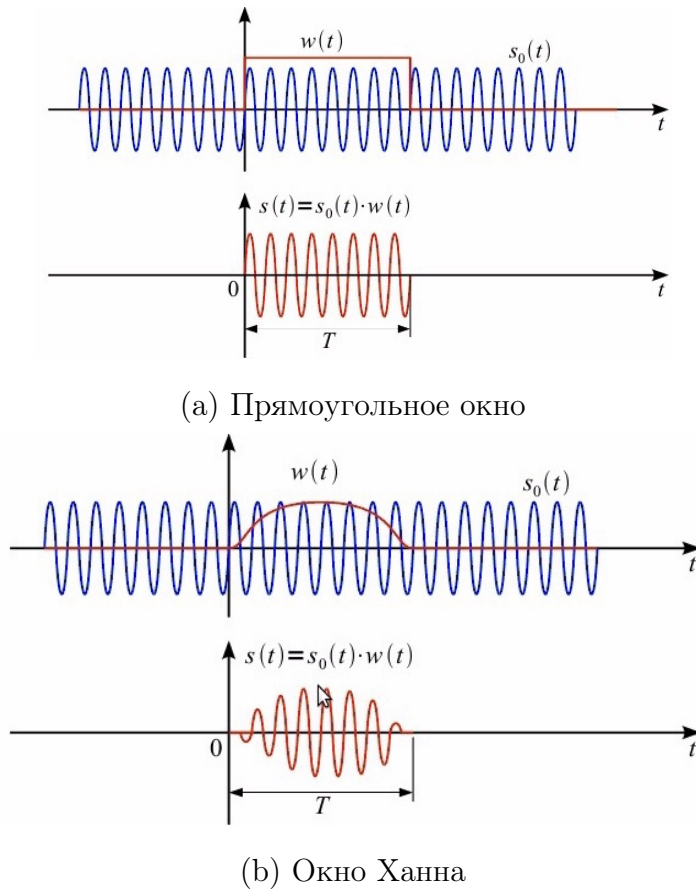


Рис. 6: Примеры применения оконных функций.

равные промежутки времени с определённой частотой дискретизации. Дискретное преобразование Фурье ставит в соответствие временной функции $f(n)$, которая определена N точками измерений на заданном временном интервале, другую функцию $F(k)$, которая определена на частотном интервале. Следует отметить, что функция на временном интервале задается с помощью N отсчётов, а функция на частотном интервале задается с помощью K -кратного спектра.

$$F(k) = \sum_{n=0}^{N-1} f(n)e^{-\frac{2\pi i}{N}kn} \quad (2)$$

Быстрое преобразование Фурье (БПФ, Fast Fourier transform - FFT) представляет собой определенный алгоритм вычисления, который позволяет умень-




Рис. 7: Преобразование Фурье позволяет рассматривать сложный временной сигнал в частотной области.

шить количество производимых действий относительно прямого (по формуле) вычисления ДПФ. В настоящее время известны несколько алгоритмов быстрого преобразования Фурье, которые являются частными случаями единого алгоритма, базирующегося на задаче разбиения одного массива чисел на два с последующим рекурсивном вычислении каждого массива чисел по дискретному преобразованию Фурье и объединении результатов расчетов.

На практике для обработки ЭЭГ сигнала используется ДПФ или БПФ. Таким образом, после применения преобразования Фурье для каждого сегмента, из представления сигнала в виде временных рядов получается его представление в частотной области, позволяя в дальнейшем выделять признаки независимо для каждой из полосы частот спектра (Рис. 8). В качестве информативных функций можно использовать следующие показатели: максимальное, минимальное, среднее значения амплитуды и сумма.

Вейвлет-преобразование (англ. Wavelet transform) – интегральное преобразование, которое представляет собой свертку вейвлет-функции с сигналом. Вейвлет-преобразование переводит сигнал из временного представления в частотно-




Рис. 8: Разделение на частотные полосы после преобразования Фурье

временное. В его основе лежат так называемые вейвлеты (с фр. маленькая волна) – функции, определяющие какой вид будет иметь анализируемый сигнал после преобразования. В то время как в преобразовании Фурье используются бесконечные функции синусоиды. Вейвлет преобразование сигнала $f(t)$ имеет вид:

$$W(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} f(t) \psi^* \left(\frac{t - \tau}{s} \right) dt. \quad (3)$$

где τ – сдвиг по времени, s – временной масштаб, а ψ^* – материнский вейвлет.

С помощью вейвлет-преобразования можно получить так называемый локальный спектр – спектр отрезка сигнала без потерь в частотной составляющей. На сегодняшний день существует более 400 видов вейвлетов, в исследованиях ЭЭГ чаще всего используются гармонические вейвлеты Морле или Добеши [22].

Итак, ЭЭГ сигнал может быть представлен во временной, частотной или частотно-временной областях для его анализа. В работе [23] представлен подробный обзор различных методов извлечения признаков из ЭЭГ. Ниже представлены несколько примеров межканальных характеристик, которые могут быть рассчитаны:

1. Среднеквадратическое отклонение

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^n S_n^2} \quad (4)$$

где S_i — амплитуда i -го канала.

2. Коэффициент корреляции Пирсона между 2 каналами

$$PCC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (5)$$

3. Оценка квадрата когерентности

$$MSCE = \frac{|P_{ij}|}{P_i \cdot P_j} \quad (6)$$

где P_i — power spectral density (PSD) i -го канала, P_{ij} — кросс-PSD i, j -го каналов.

1.3 Классификация с помощью машинного обучения

Задача классификации – задача, в которой имеется множество объектов, разделённых некоторым образом на классы. Задано конечное множество объектов, для которых известно, к каким классам они относятся. Это множество называется выборкой. Классовая принадлежность остальных объектов неизвестна. Требуется построить алгоритм, способный классифицировать произвольный объект из исходного множества. Задача классификации относится к обучению с учителем. Далее будут рассмотрены два из наиболее часто встречающихся алгоритмов машинного обучения для решения задачи классификации – метод опорных векторов (англ. SVM, Support Vector Machine) и Random Forest.




Рис. 9: Метод опорных векторов (SVM).

Метод опорных векторов или **метод классификатора с максимальным зазором**. Рассматривается задача классификации векторов с n признаками $x = (x_1, x_2, \dots, x_n)$ в пространстве R^n , где каждый из векторов принадлежит только к одному из двух классов. Главная цель SVM-классификатора – найти уравнение гиперплоскости $w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$ в R^n , разделяющей два класса опти-

мальным способом. Общий вид преобразования вектора x в искомую метку класса

$$Y : F(x) = \text{sign}(w^T x - b), \quad (7)$$

где $w = (w_1, w_2 + \dots + w_n), b = -w_0$. Функция преобразования зависит от линейной комбинации признаков объекта с весами алгоритма, поэтому SVM относится к линейным алгоритмам. Разделяющую гиперплоскость можно построить разными способами, но в SVM веса w и b настраиваются таким образом, чтобы векторы классов лежали как можно дальше от разделяющей гиперплоскости. Другими словами, алгоритм максимизирует зазор между гиперплоскостью и векторами классов, которые расположены ближе всего к ней. Такие ближайшие к гиперплоскости векторы и называют опорными векторами.

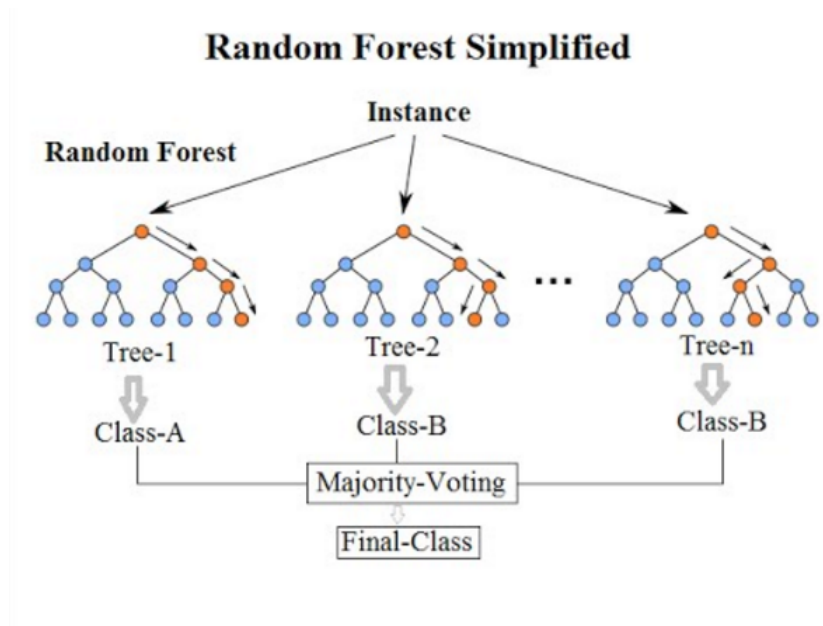


Рис. 10: Random Forest классификатор.

Random Forest. В этом методе рассматривается задача классификации по неполному количеству признаков для обучения методом построения деревьев. Пусть имеется N векторов из обучающей выборки, где размерность каждого вектора (размерность пространства признаков) равна M , и задан параметр m как

неполное количество признаков для обучения. Алгоритм обучения, называемый бэггинг (англ. bagging), заключается в построении ансамбля деревьев, называемого комитетом, где каждое дерево классифицирует образцы из выборки, однако качество классификации весьма низкое. За счёт большого количества деревьев в ансамбле при применении этого алгоритма удаётся существенно повысить качество. Все деревья строятся по одному и тому же алгоритму:

1. Генерируется случайная подвыборка с повторениями размером N из обучающей выборки. Получается, что часть образцов попадёт в неё больше одного раза, а в приблизительно $(1 - 1/N)^N$ образцов не попадут в неё вообще. Образцы, невошедшие в случайную выборку называются неотобранными (out-of-bag).
2. Строится решающее дерево, классифицирующее образцы данной подвыборки, причём в ходе создания очередного узла дерева выбирается набор только тех m признаков, на основе которых производилось разбиение. Выбор наилучшего из этих m признаков может осуществляться различными способами. В коде Бреймана [24] используется критерий Джини [25], применяющийся также в алгоритме построения решающих деревьев CART [26]. В некоторых реализациях алгоритма вместо него используется критерий прироста информации [26].
3. Далее дерево строится до полного исчерпания подвыборки и не подвергается процедуре отсечения ветвей, в отличие от решающих деревьев, построенных, например, при помощи алгоритма CART.

Классификация объектов проводится путём голосования: каждое дерево построенного ансамбля относит классифицируемый объект к одному из классов, и результирующим выбирается класс, за который проголосовало наибольшее число деревьев. Что касается необходимого количества построенных деревьев, то оптимальное их число подбирается так, чтобы минимизировать ошибку классифи-

катора на тестовой выборке.

Одним из достоинств алгоритма Random Forest является то, что при его использовании одинаково хорошо обрабатываются не только дискретные, но и непрерывные признаки, что позволяет использовать алгоритм для решения задачи регрессии (предсказания числого значения независимой переменной для заданного входного вектора).

1.4 Нейронные сети

Нейронные сети в машинном обучении – совокупность связанных между собой искусственных нейронов, отдельных структурных единиц, которые в первом приближении имитируют свойства биологического нейрона. Нейрон имеет некоторое количество входов, называемых также синапсами. Каждый вход в нейрон умножается на соответствующий вес, аналогичный синаптической силе в биологическом нейроне, и все произведения суммируются, определяя уровень активации нейрона. Хотя нейронные сети бывают различными, в большинстве их лежит следующая конфигурация:




Рис. 11: Искусственный нейрон с функцией активации.

$$NET = \sum_{i=1}^n w_i x_i + w_0, OUT = F(NET) \quad (8)$$

Здесь множество сигналов x_1, x_2, \dots, x_n поступают на вход нейрону, домножаясь на соответствующие веса w_1, w_2, \dots, w_n , полученный выход NET как правило обрабатывается функцией активации и даёт выходной сигнал OUT, w_0 - биас (смещение) нейрона.

Нейронные сети являются универсальным средством аппроксимации функций, что позволяет их использовать в решении задач классификации. Как правило, нейронные сети оказываются наиболее эффективным способом классификации, потому что генерируют фактически большое число регрессионных моделей (кото-

рые используются в решении задач классификации статистическими методами). Сегодня, нейронные сети используются повсеместно.

Процесс обучения нейронной сети состоит из нескольких этапов.

1. Первоначально весам модели присваиваются случайные значения, затем первые данные подаются на вход нейросети, где к ним применяются функции активации нейронов.
2. Рассчитанные нейросетью значения сравниваются с эталонными значениями, метрикой различия служит некоторая функция потерь.
3. После расчета разницы между предсказанными и эталонными значениями, начинается обратный проход. С помощью градиентного спуска рассчитывается отрицательный градиент функции потерь для её минимизации. На значение рассчитанного градиента обновляются параметры модели, и цикл обучения продолжается до тех пор, пока не будет достигнуто желаемое качество модели.

После завершения обучения, модель становится черным ящиком, на вход которому подаются данные, обработав которые, на выходе получается вероятность принадлежности объекта к тому или иному классу.

Далее будут рассмотрены строение некоторых нейронных сетей, применяемых при решении исследуемой в настоящей работе задачи классификации ЭЭГ сигнала, а именно распознавания эмоций человека.

Полносвязные нейронные сети. Полносвязная нейронная сеть прямого распространения – это сеть, в которой каждый нейрон связан со всеми остальными нейронами, находящимися в соседних слоях, и в которой все связи направлены строго от входных нейронов к выходным.

Свёрточные нейронные сети. В сверточной нейронной сети выходы промежуточных слоев образуют матрицу или набор матриц. Основными видами слоев




Рис. 12: Строение полносвязной нейронной сети

в сверточной нейронной сети являются сверточные слои, пулинговые слои и полносвязные слои.

- Сверточный слой нейронной сети является результатом операции свертки применённой к выходам с предыдущего слоя, где веса ядра свертки являются обучаемыми параметрами. Операция свёртки это преобразование над парой матриц A размера $n_x \times n_y$ и B размера $m_x \times m_y$, результатом которой является матрица $C = A * B$ размера $(n_x - m_x + 1) \times (n_y - m_y + 1)$. Каждый элемент результата вычисляется как скалярное произведение матрицы B и некоторой подматрицы A такого же размера.
- Пулинговый слой призван снижать размерность матрицы. Исходная матрица делится на блоки размером $w \times h$ и для каждого блока вычисляется некоторая функция. Чаще всего используется функция максимума или взвешенного среднего.

Первоначально применение свёрточных нейросетей было нацелено на рас-




Рис. 13: Строение свёрточной нейронной сети

познавание изображений, но в дальнейшем они стали успешно применяться и в других областях.

Автокодирующие нейронные сети. Простейшая архитектура автокодирующей нейронной сети – сеть прямого распространения, без обратных связей, наиболее схожая с полносвязной нейронной сетью и содержащая входной слой, промежуточный слой и выходной слой. В отличие от полносвязных сетей, выходной слой автокодировщика должен содержать столько же нейронов, сколько и входной слой.

Главный принцип работы и обучения автокодирующей нейронной сети – получение на выходном слое отклика, который был бы наиболее близок к входному. На промежуточный слой автокодировщика обязательно накладывают ограничения: промежуточный слой должен быть или меньшей размерности, чем входной и выходной слои, или искусственно ограничивается количество одновременно активных нейронов промежуточного слоя, что называется разрежённой активацией. Эти ограничения заставляют нейросеть искать обобщения и корреляцию в поступающих на вход данных, выполнять их сжатие. Таким образом, нейросеть автоматически обучается выделять из входных данных общие признаки, которые кодируются в значениях весов искусственной нейронной сети.




Рис. 14: Автокодирующая нейронная сеть.

Использование рассмотренных выше нейронных сетей для классификации ЭЭГ сигналов было продемонстрировано, например:

- В работе [27]. В ней было предложено последовательное применение автокодировщика, сверточного модуля и полносвязной нейронной сети для эффективного применения классификационной и регрессионной модели для построения предсказаний моторновизуальных активностей или эмоционального состояния человека.
- В работе [28] метод независимых компонент, используемый для очистки сигнала, был заменен частью архитектуры нейронной сети, состоящей из автокодирующих блоков. Такой подход позволил в рамках одной нейросетевой архитектуры решить и задачу устранения артефактов, и задачу распознавания эмоций.
- В работе [29] сигнал ЭЭГ представлялся в трёхмерном виде и в дальнейшем подавался на вход трёхмерной свёрточной нейронной сети для классификации эмоций.

1.5 Методы доменной адаптации

Доменная адаптация призвана решать проблему снижения качества обученной модели при её применении к доменам, не участвовавшим в обучении и некоторым образом отличающихся от тренировочных данных. Например, обучая модель для классификации эмоций по измерениям ЭЭГ на данных, собранных с одного человека, при попытке классифицировать данные (домен) другого человека будет значительно снижаться качество предсказания. В доменной адаптации данных ЭЭГ наилучшие результаты показали методы предобработки данных Transfer Component Analysis (ТСА) и Maximum Independence Domain Adaptation (MIDA). Применение этих технологий приводит к значительному повышению точности по сравнению с базовой точностью, где не использовался метод адаптации домена.

Метод **ТСА** заключается в попытке сгладить несоответствие между доменами путём минимизации среднего расхождения (MDD) в ядре Гильбертова пространства (RKHS) [30], которое измеряет расстояние между средними значениями исходного и целевого доменов. Интуитивно понятно, что когда расстояние между средними значениями обоих доменов невелико, данные, как правило, распределяются одинаково в обоих доменах. Было доказано, что, когда RKHS является универсальным, MMD будет асимптотически приближаться к нулю тогда и только тогда, когда два распределения в двух доменов идентичны [31].

Алгоритм **MIDA** стремится максимизировать независимость между доменами и их соответствующими доменными характеристиками, измеряемыми с помощью критерия независимости Гильберта-Шмидта (HSIC) [32].

В статье «Domain Adaptation for EEG Emotion Recognition Based on Latent Representation Similarity» [33] был рассмотрен подход решения задачи доменной адаптации, основанный на нейронных сетях. Используется нейросеть состоящая из трёх частей. Сначала нейросеть выделяет векторное представление из данных, которое передаётся отдельно в две компонентны сети, одна из которых отвечает за

классификацию на исходном домене, а вторая обучается отличать данные исходного домена от целевого. Во время обучения при обратном распространении ошибки из второй компоненты используется Gradient Reversal Layer, который умножает проходящий через него градиент на негативную константу, увеличивая доменный loss. Этим добиваются того, что распределение векторных представлений на обоих доменах становятся близкими.

2 Исследование и построение решения

Прежде чем приступать к решению практических задач необходимо получить доступ к датасетам, которые имеют метки, соответствующие эмоциям, и обладают достаточным размером и качеством для проведения содержательных экспериментов над ними. DEAP и SEED – самые распространённые размеченные датасеты измерений ЭЭГ сигналов человека для распознавания по ним эмоций. В данной работе будут рассматриваться эти два набора данных.

2.1 Общее решение задачи распознавания эмоций

Над обоими датасетами проведена предварительная обработка авторами этих наборов данных, поэтому этап с очисткой данных отсутствует. Для распознавания эмоций по ЭЭГ из данных сначала выделяются определённые признаки, затем для классификации данных по полученным признакам были использованы методы машинного и глубокого обучения с использованием свёрточной нейросети.

2.1.1 Извлечение признаков

Для извлечения признаков из сигнала можно разбить его на короткие сегменты равной длины и извлечь характеристики из каждого фрагмента. Полученные признаки для обучения могут быть представлены разными способами:

1. Для каждого сегмента вытягивать значения по каналам в один вектор и получится последовательность одномерных векторов для всех субъектов и сессий, на которой будет происходить обучение классификатора.
2. Можно производить обучение и на двумерных векторах, в случае, когда ЭЭГ каналы не вытягиваются в один вектор и выступают дополнительной размерностью векторов, или при разделении спектра на частотные полосы, эти полосы выступают каналами.

3. Данные могут представляться в виде трёхмерных векторов, например, с использованием вейвлет-преобразования добавляется размерность за счёт представления данных в нескольких каналах в частотно-временном представлении. Или можно получить представление ЭЭГ каналов на двумерной карте в соответствии с расположением электродов на голове. Если разным частотным ритмам поставить в соответствие RGB цвета, то можно получить цветное представление сигнала на изображении и получить трёхмерные векторы, как это было предложено в работе [34].

Были выбраны следующие два способа извлечения признаков:

1. К каждому сегменту применяется преобразование Фурье. Затем из полученного спектра, значения спектральной мощности можно сгруппировать по частотным полосам, получив для каждого сегмента данных набор векторов по каждому каналу, преобразовав его в одномерный вектор.
2. Для каждого сегмента получен 3D вектор признаков после применения вейвлет-преобразования с материнским вейвлетом Добеши.

2.1.2 Классификация

1. Для лучшей классификации метки на данных бинаризируются, разделив все данные только на два класса. В датасете DEAP например, используются шкалы от 0 до 9, классификацию по такому количеству классов проводить сложнее, в то время как эмоции с соседними значениями схожи.
2. Наборы данных, размеченные эмоциями по шкалам валентности, возбуждённости и интенсивности, исследуются отдельно, то есть независимо настраиваются модели для классификации по разным шкалам.
3. Непосредственно для классификации используются SVM классификатор, Random Forest Regression, а также проводится обучение нейронной сети. Была построена

на свёрточная нейросеть, в которой чередуются свёрточные слои, слои пулинга и активации, которые отдают результат в полносвязный слой, а в качестве функции потерь выступает кросс-энтропия.

2.2 Доменная адаптация

2.2.1 Эксперименты для сравнения точности на разных доменах

В рамках задачи распознавания эмоций по ЭЭГ доменами могут являться как множества измерений разных людей (субъектов), так и множества сессий одного и того же субъекта. Разные датасеты также могут выступать доменами при обучении из-за собственных особенностей представления данных, а также физических характеристик измерительной аппаратуры и разницы условий проведения измерений.

Используя алгоритмы классификации, описанные выше: SVM и Random Forest Regression, проведём сравнение точности распознавания эмоций субъекта в случае когда его данные присутствуют в обучающей выборке и когда они в ней отсутствуют.

Нейросеть же будем обучивать и тестировать на двух доменах, которые являются различными датасетами. Сперва обучим нейросеть на датасете SEAD и протестируем на данных из DEAP, а затем повторим тоже самое поменяв датасеты местами.

2.2.2 Построение нейросетевой архитектуры для доменной адаптации

Будем использовать подход, рассмотренный в работе [33]. В качестве структуры классификатора – выбрана свёрточная нейронная сеть, в которую после свёрточных слоёв добавляется доменный классификатор, который предназначен для того, чтобы распознавать принадлежность данных к тому или иному домену и при обратном проходе обновлять параметры для извлечения признаков путем связы-

тельного обучения. Такой подход является попыткой сделать распределение представлений данных из различных доменов более схожим.

Для того чтобы решить проблему доменной адаптации, используя обучение нейронной сети, предлагается обучать нейронную сеть не только на размеченных по эмоциям данных, но также использовать и неразмеченные данные для обучения. Причём неразмеченных данных значительно больше, чем размеченных.

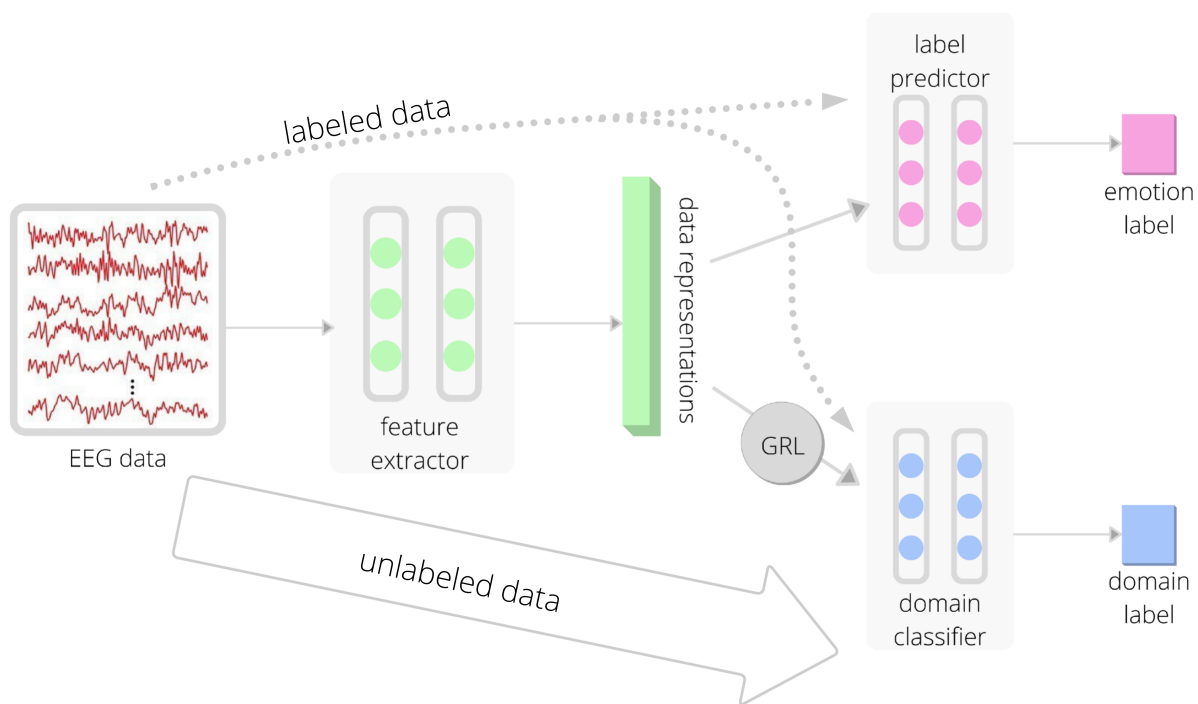


Рис. 15: Архитектура нейросети с доменным классификатором

3 Описание практической части

Для написания исполняемого кода практической части был выбран язык программирования Python 3, предобработка данных в .mat формате проводилась с помощью Matlab. Для анализа данных были использованы такие python-библиотеки, как numpy, pandas, pytorch, sklearn. Эксперименты запускались на платформах Google Colab [35] и Kaggle [36] с использованием GPU.

3.1 Наборы данных

3.1.1 DEAP

Датасет DEAP (A Database for Emotion Analysis Using Physiological Signals) [19] широко используется в работах по распознаванию эмоций на основе ЭЭГ [37–39]. Этот набор данных был собран в рамках разработки адаптивной системы рекомендаций по музыкальным видео. В эксперименте приняли участие 32 человека. Данные были записаны у пациентов при просмотре 40 одноминутных музыкальных видеоклипов – стимулов эмоций. Во время эксперимента участники проводили самооценку своих эмоций по шкалам возбуждения, валентности и доминирования (Рис. 16). В результате были получены многоканальные записи, содержащие ЭЭГ сигнал и периферийные физиологические сигналы, такие как температура тела, сердцебиение. Для 22 из 32 участников было также записано фронтальное видео. Кроме того, в датасете содержатся названия и ссылки на просматриваемые участниками видео. Набор данных открыт только для академических исследований и доступен для загрузки после подписания лицензионного соглашения EULA.

Набор данных удобен тем, что содержит не только исходные данные в формате BDF (Biosemi Data Format) – стандартном для записи ЭЭГ сигнала, но и предварительно обработанные данные в форматах, удобных для использования в Matlab и Python: .mat и .dat. Наличие предобработанных данных в датасете поз-




Рис. 16: Self-Assessment Manikin(SAM) для оценки эмоций по шкалам возбуждения, валентности и доминирования [40].

воляет проводить анализ не на сырых исходных данных и пропустить этап очистки данных от артефактов. Авторами датасета были удалены ЭОГ артефакты, применён полосовой частотный фильтр, и данные были сегментированы и приведены к удобному для дальнейшего анализа формату с частотой записи 128 Гц. Предобработанные данные для python – это архив **data_preprocessed_python.zip**, содержащий 32 .dat файла, каждый из которых соответствует записям для одного участника эксперимента. В python удобно загружать содержимое файлов с помощью модуля *cPickle*:

```
import cPickle
x = cPickle.load(open('s01.dat', 'rb'))
data = x['data']
labels = x['labels']
```

Таким образом, из каждого файла можно получить следующие векторы:

Каждый пациент просмотрел 40 видео и оценил своё ментальное состояние во время просмотра каждого видео по 4 шкалам. И каждому видео соответствует 40-канальный сигнал (32 канала соответствуют электроэнцефалограмме, а остальные 8 каналов – периферийные сигналы) продолжительностью 63 секунды с ча-

Вектор	Размерность	Интерпретация
data	40 x 40 x 8064	видео x каналы x сигнал
labels	40 x 4	видео x метки (по шкалам valence, arousal, dominance, liking)

стотой записи 128 Гц, где первые 3 секунды – запись во время подготовки без просмотра видео.

3.1.2 SEED

Датасет SEED (SJTU Emotion EEG Dataset) [41; 42] содержит данные 15 испытуемых, снятые за 3 сеанса с интервалом около одной недели. Во время каждого сеанса участники эксперимента просматривали 15 видеоклипов с разной продолжительностью более 1 минуты каждый. Каждое видео оценено в терминах “положительных”, “отрицательных” или “нейтральных” вызываемых эмоций, соответственно каждой категории выставлены числовые оценки +1, 0 или -1. Набор данных состоит из предварительно обработанных электроэнцефаллограмм и извлечённых из данных характеристик. Папка **Preprocessed_EEG** содержит 45 .mat (Matlab) файлов, каждый файл соответствует записям одного испытуемого во время определённой сессии. Файлы состоят из 15 массивов – на каждое просмотренное видео. Размерность массивов: 62 канала ЭЭГ x продолжительность записи. Данные сохранены с частотой записи 200 Гц и очищены от артефактов. Вторая папка **Extracted_Features** содержит файлы в Matlab формате с извлечёнными признаками – дифференциальной энтропией (DE - differential entropy) ЭЭГ сигналов.

3.2 Предобработка данных

3.2.1 Представление данных в виде одномерных векторов

Для обучения классификаторов были использованы предобработанные данные датасета DEAP. Извлечение признаков для этого было реализовано на языке программирования Python и запускалось на платформе Google Colab. Для каждого .dat файла субъекта были получены векторы с характеристиками с помощью следующих шагов:

1. Из записи были удалены первые 3 секунды. Так как частота записи - 128 Гц, то обрезаются первые 384 значения.

$$(40 \times 40 \times 8064) \rightarrow (40 \times 14 \times 7680)$$

2. Были выбраны 14 ЭЭГ каналов: Fp1, AF3, F3, F7, FC1, P3, PO3, Fp2, Fz, F4, F8, C4, P4, PO4.

$$(40 \times 40 \times 7680) \rightarrow (40 \times 14 \times 7680)$$

3. Данные были разбиты на двухсекундные сегменты с шагом 0.125с. Получилось 488 сегментов.

4. Для каждого сегмента было применено быстрое преобразование Фурье с помощью функции *numpy.fft*.

5. Полученные значения спектральной плотности мощности были сгруппированы по 5 частотным полосам: альфа, бета, гамма, дельта, тетта (Рис. 8).

6. Внутри каждой группы были просуммированы значения. Для каждого сегмента получилось 5 значений.

7. Для каждого сегмента значения по каналам были вытянуты в один вектор.

$$(40 \times 14 \times 7680) \rightarrow (40 \times 488 \times 70)$$

8. Значения по каждому видео были вытянуты в один вектор.

$$(40 \times 488 \times 70) \rightarrow (19520 \times 70)$$

В итоге была получена последовательность из одномерных векторов, каждый из которых содержит 70 числовых значений. Эти данные были сохранены в файле .pru формата для удобного сохранения numpy массива.

3.2.2 Представление данных в виде 3D векторов

Для обучения нейросети на вход подавались 3D вектора. Обучение проводилось и на наборе данных DEAP, и на SEED. Процедуры предварительной подготовки данных для обоих датасетов были схожи. И так как в наборе данных SEED присутствуют только файлы .mat формата, то извлечение признаков было реализовано в Matlab.

На наборе данных DEAP для каждого .mat файла, соответствующего преобразованной ЭЭГ записи одного пациента, проводилась следующая последовательность действий:

1. Данные по каждому просмотренному видео обрабатывались отдельно.

$$(40 \times 40 \times 8064) \rightarrow 40 \text{ векторов } (40 \times 7680)$$

2. Из записи были удалены первые 3 секунды.

$$(40 \times 8064) \rightarrow (40 \times 7680)$$

3. В дальнейшей обработке участвовали только ЭЭГ каналы, поэтому каналы, соответствующие периферийным сигналам были удалены.

$$(40 \times 7680) \rightarrow (32 \times 7680)$$

4. Исходные данные были преобразованы в вейвлет-коэффициенты посредством непрерывного вейвлет-преобразования, а затем в энергию вейвлета (скалограммы). Для этого использовались функции *cwt* с параметром *wname="db4"*

и *wscalogram*.

$$(32 \times 7680) \rightarrow (32 \times 64 \times 7680)$$

5. Затем данные были разбиты на фрагменты с длиной 1 секунда, и значения внутри каждого фрагмента были просуммированы.

$$(32 \times 64 \times 7680) \rightarrow (32 \times 64 \times 60)$$

6. Для уменьшения размера вектора данных был сокращён масштаб по второй размерности.

$$(32 \times 64 \times 60) \rightarrow (32 \times 32 \times 60)$$

7. Для сохранения данных в csv формате размерность данных была снижена до (1024×3) . В итоге были получены 1280 csv файлов, каждый из которых соответствовал записи ЭЭГ для 1 участника при просмотре 1 видео. После загрузки в Python данные были возвращены в представление в виде 3D векторов с размерностью $(32 \times 32 \times 60)$

8. Каждый вектор был разбит на 20 векторов, содержащих данные за 3 секунды. 1280 векторов $(32 \times 32 \times 60) \rightarrow 1280 \times 20$ векторов $(32 \times 32 \times 3)$

По завершении всех шагов была получена последовательность из 3D векторов в numpy формате, готовая для использования при обучении и тестировании нейросети.

Для **набора данных SEED** была проведена аналогичная процедура. После выполнения обработки в Matlab было получено 675 csv файлов (15 участников * 3 сессии * 15 видео) с размером таблиц 1984×60 . И после данные были трансформированы в вектора с размерностью $(62 \times 32 \times 3)$, где 62 соответствует количеству ЭЭГ каналов, 50 соответствует уровням разложения сигнала. Из 62 каналов ЭЭГ были выбраны 32 и упорядочены так же, как в датасете DEAP, для дальнейшего сравнения обучения на этих двух датасетах.

3.3 Сравнение обучения при разном разбиении на выборки

Для иллюстрация того факта, что проблема междоменной адаптации действительно требует решения, был проведен эксперимент, демонстрирующий снижение точности распознавания эмоций при отсутствии данных о субъектах в обучающей выборке. Были использованы предварительно обработанные данные датасета DEAP и извлечены признаки с представлением данных последовательностью одномерных векторов. Данные были разделены на обучающую и тестовую выборки в соотношении 7 : 1 соответственно. В первом эксперименте данные каждого испытуемого были разделены между выборками в соответствующем соотношении. Во втором эксперименте данные каждого испытуемого полностью содержались в той или иной выборке.

(a) Для SVM

Шкалы оценки эмоций	1-й эксперимент	2-й эксперимент
Валентность	68.4%	52.2%
Возбуждённость	65.1%	57.7%
Интенсивность	68.9%	52.4%

(b) Для Random Forest Regression

Шкалы оценки эмоций	1-й эксперимент	2-й эксперимент
Валентность	83.2%	47.6%
Возбуждённость	82.6%	60.3%
Интенсивность	81.8%	53.1%

Таблица 1: Результаты экспериментов

Были обучены следующие классификаторы: SVM, Random forest regression. Для обучения SVM использовалась библиотека *sklearn*, модуль *svm*, обучение проводилось без дополнительных параметров. Для Random forest regression также ис-

пользовалась библиотека *sklearn*, модуль *ensemble*. Модель *RandomForestRegressor* была обучена с параметрами $n_estimators=512$, $n_jobs=6$, подобранными экспериментально. В таблице 1 показаны различия в точности определения эмоций для этих двух экспериментов. В результате можно увидеть проблемы в обучении по изолированным субъектам.

3.4 Распознавание эмоций с помощью глубокого обучения

Свёрточная нейросеть (Рис. 17) состоит из 3 блоков, каждый включающий в себя два свёрточных слоя с размером ядра 3, MaxPooling слой с ядром размера 2 и слой активации ReLU. После прохождения этих блоков размерность входного вектора трансформируется из $(32 \times 32 \times 3)$ в $(128 \times 4 \times 4 \times 1)$. Этот вектор преобразуется в одномерный и передаётся в полносвязный слой. Архитектура была реализована с помощью python библиотеки *pytorch*. Обучение нейросети проводилось с параметрами, представленными в Таблице 2.




Рис. 17: Архитектура нейросети

Параметр	Значение
Функция потерь	Кросс-энтропия
Оптимизатор	Адам
Количество эпох	50
Коэффициент скорости обучения	0.0001

Таблица 2: Параметры нейросети

Каждый датасет был разделён на обучающую и тестовую выборки в соотношении 9:1, и была обучена описанная нейросеть, результаты приведены в Таблице 3.

(a) На датасете DEAP

Шкалы	Train	Test
Valence	93.2%	71.9%
Arousal	84.7%	62.7%
Dominance	87.4%	63.0%

(b) На датасете SEED

Классы	Train	Test
3 эмоции	79.4%	54.0%
2 эмоции	86.0%	73.9%

Таблица 3: Точность распознавания

3.5 Доменная адаптация

Далее проводились эксперименты по исследованию междоменной изменчивости и применению состязательного обучения в качестве доменной адаптации, где доменами выступали разные датасеты. Чтобы проводить обучение на одном датасете, а

распознавание на другом, необходимо привести в соответствие метки. Для датасета DEAP была выбрана шкала валентности, так как она соответствует классификации положительные - негативные эмоции. Для датасета SEED произведён переход от классификации по 3 эмоциям с метками -1, 0, 1 к 2 эмоциям с метками 0 (-1) и 1 (0, 1).

Модели, обученные на одном датасете, были протестированны на другом. Результаты можно увидеть в Таблице 4 в столбце CNN, который соответствует обучению свёрточной нейросети из предыдущего раздела 3.4.

Затем нейросеть была модифицирована для состязательного обучения: после свёрточных слоёв происходит разветвление на классификатор эмоций и доменный классификатор, каждый состоящий из полносвязного слоя, и перед доменным классификатором стоит Gradient Reversal Layer, где градиент домножается на $-\lambda$, вычисляемую по формуле 9, как в [44]. А коэффициент скорости обучения μ вычисляется по формуле 10.

$$\lambda = \frac{2}{1 + e^{-10p}} - 1 \quad (9)$$

$$\mu = \frac{0.01}{(1 + 10p)^{0.75}} \quad (10)$$

где p постепенно увеличивается от 0 до 1 с увеличением шага обучения.

Эксперимент	CNN	CNN+GRL
Обучение на DEAP, тест на SEED	52.5%	66.3%
Обучение на SEED, тест на DEAP	51.1%	56.7%

Таблица 4: Сравнение точности распознавания эмоций на датасете при обучении классификации эмоций на другом датасете

Результаты можно увидеть во втором столбце CNN+GRL Таблицы 4, и можно заметить, что они улучшились по сравнению с предыдущим экспериментом,

хоть и точность ниже, чем при присутствии в обучающей выборке данных из тестируемого домена.

Заключение

В рамках работы была изучена задача распознавания эмоций человека по данным ЭЭГ. Были получены доступы к двум размеченным датасетам, с помощью которых после определённой предобработки были обучены два классификатора SVM и RandomForest Regression. На примере распознавания эмоций у разных субъектов используя эти классификаторы продемонстрирована проблема доменной адаптации. Далее в ходе работы в рамках исследования различных методов классификации была построена свёрточная нейросеть, которая затем была обучена на обоих датасетах. Также проведены эксперименты, в которых нейросеть обучалась на одном датасете (домене), а тестировалась на другом. В этом случае качество прогнозирования было минимально, что наглядно показало проблему доменной адаптации. Для решения этой проблемы было использовано состязательное обучение: в нейросеть был добавлен дополнительный слой доменного классификатора и отрицательный градиентный слой. Для состязательного обучения также использовался один датасет, и тестирование обученной модели происходило на другом датасете. Результаты показали, что применение состязательного обучения улучшают качество прогнозирования при обучении и тестировании на разных доменах. Для улучшения качества была предложена идея дополнительного обучения доменного классификатора в нейросети на неразмеченных данных.

Список литературы

- [1] Bobrov P, Frolov A, Cantor C, Fedulova I, Bakhnyan M, et al. (2011) Brain-Computer Interface Based on Generation of Visual Images. PLoS ONE 6(6): e20674. doi: 10.1371/journal.pone.0020674
- [2] Stewart, J. L., Coan, J. A., Towers, D. N., Allen, J. J. B.: Frontal EEG asymmetry during emotional challenge differentiates individuals with and without lifetime major depressive disorder. *Journal of Affective Disorders* **129**(1-3), 167–174 (2011). doi: 10.1016/j.jad.2010.08.029
- [3] Yin, Z., Wang, Y., Liu, L., Zhang, W., Zhang, J.: Cross-Subject EEG Feature Selection for Emotion Recognition Using Transfer Recursive Feature Elimination. *Frontiers in Neurorobotics* **11** (2017). doi: 10.3389/fnbot.2017.00019
- [4] Urgen, B., Plank, M., Ishiguro, H., Poizner, H., Saygin, A.: Eeg theta and mu oscillations during perception of human and robot actions. *Frontiers in Neurorobotics* **7** (2013). doi: 10.3389/fnbot.2013.00019
- [5] Calvo, R. A., D’Mello, S.: Affect detection: An interdisciplinary review of models, methods, and their applications. *IEEE Transactions on affective computing*, **1**(1), 18–37 (2010).
- [6] Yadava, M., Kumar, P., Saini, R. et al: Analysis of EEG signals and its application to neuromarketing. *Multimedia Tools and Applications* **76**, 19087–19111 (2017). doi: 10.1007/s11042-017-4580-6
- [7] Kothe, C. A., Makeig, S.: Estimation of task workload from EEG data: new and current tools and perspectives. In: Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 6547–6551. EMBC, IEEE (2011).

- [8] Shi, L. C., Lu, B. L.: EEG-based vigilance estimation using extreme learning machines. *Neurocomputing* **102**, 135–143 (2013).
- [9] Muse Homepage, <https://choosemuse.com>
- [10] Emotiv Homepage, <https://www.emotiv.com>
- [11] Neurosky Homepage, <http://neurosky.com>
- [12] Ray W. J., Cole H. W. EEG alpha activity reflects attentional demands, and beta activity reflects emotional and cognitive processes // *Science*. – 1985. – T. 228. – №. 4700. – C. 750-752.
- [13] Lopez-Calderon, J., Luck, S. J.: ERPLAB: an open-source toolbox for the analysis of event-related potentials. *Frontiers in Human Neuroscience* **8** (2014). doi: 10.3389/fnhum.2014.00213
- [14] Brunner, D. P., Münch, M., Biedermann, K., Huch, R., Huch, A., Borbély, A. A.: Changes in Sleep and Sleep Electroencephalogram During Pregnancy. *Sleep* **17**(7), 576–582 (1994). doi: 10.1093/sleep/17.7.576
- [15] Sebe, N., Lew, M. S., Cohen, I., Garg, A., Huang, T. S.: Emotion recognition using a cauchy naive bayes classifier. In: *Object recognition supported by user interaction for service robots* **1**, pp. 17-20. IEEE (2002).
- [16] Lang, P. J.: The emotion probe: studies of motivation and attention. *American psychologist* **50**(5), 372 (1995).
- [17] Scherer, K. R.: What Are Emotions? And How Can They Be Measured? *Social Science Information* **44**(4), 695–729 (2005). doi: 10.1177/0539018405058216
- [18] Shu, L., Xie, J., Yang, M., Li, Z., Li, Z., Liao, D., Yang, X.: A review of emotion recognition using physiological signals. *Sensors* **18**(7), 2074 (2018).

- [19] Koelstra, S., Muhl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., Patras, I.: Deap: A database for emotion analysis; using physiological signals. *IEEE transactions on affective computing* **3**(1), 18–31 (2011). doi: 10.1109/T-AFFC.2011.15
- [20] Gibbs, J. Willard (1898), "Fourier's Series *Nature*, **59**(1522): 200. doi: 10.1038/059200b0
- [21] Grass, A. M., Gibbs, F. A.: A Fourier transform of the electroencephalogram. *Journal of Neurophysiology* **1**(6), 521–526 (1938). doi: 10.1152/jn.1938.1.6.521
- [22] Кобылат А.О. “Алгоритм проведения вейвлет-преобразования данных ЭЭГ” *Современные инновации*, no. **3**(5), 2016, стр. 22-25
- [23] Jenke, R., Peer, A., Buss, M.: Feature extraction and selection for emotion recognition from EEG. *IEEE Transactions on Affective computing* **5**(3), 327–339 (2014).
- [24] Breiman, Leo. «Random Forests». *Machine Learning* 45. 2001.: 5–32. doi: 10.1023/A:1010933404324
- [25] Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning*. 2009.
- [26] Classification and regression trees. Breiman L., Friedman J. H., Olshen R. A., & Stone C. J. Monterey, CA: Wadsworth & Brooks/Cole Advanced Books & Software, 1984.
- [27] В. Н. Захаров, С. А. Ступников, И. А. Шанин. *Математические методы анализа данных электроэнцефалографии с помощью многозадачного обучения*. Москва: ФИЦ ИУ РАН. 2020.

- [28] Duan, R. N., Zhu, J. Y., and Lu, B. L. 2013. Differential entropy feature for EEG-based emotion classification. In 2013 6th International IEEE/EMBS Conference on Neural Engineering (NER) (pp. 81-84). IEEE. doi: 10.1109/NER.2013.6695876
- [29] Shawky, Elham & El-Khoribi, Reda & Shoman, Mahmoud & Wahby Shalaby, Mohamed. (2018). EEG-Based Emotion Recognition using 3D Convolutional Neural Networks. International Journal of Advanced Computer Science and Applications. 9. 329.
- [30] A kernel method for the two-sample problem, A. Gretton, K. Borgwardt, M. Rasch, B. Schölkopf and A. Smola. in Proc. Conf. Neural Inf. Process. Syst. 19. Cambridge, MA, 2007, pp. 513–520.
- [31] A. J. Smola, A. Gretton, L. Song, and B. Schölkopf, “A Hilbert space embedding for distributions,” in Proc. 18th Int. Conf. Algorithmic Learn. Theory, Sendai, Japan, Oct. 2007, pp. 13–31.
- [32] A. Gretton, O. Bousquet, A.J. Smola, and B. Schölkopf. Measuring statistical dependence with HilbertSchmidt norms. In ALT, pages 63–77, 2005.
- [33] Li, J., Qiu, S., Du, C., Wang, Y., He, H.: Domain Adaptation for EEG Emotion Recognition Based on Latent Representation Similarity. IEEE Transactions on Cognitive and Developmental Systems. 2019. <https://doi.org/10.1109/TCDS.2019.2949306>
- [34] Bashivan, P., Rish, I., Yeasin, M., Codella, N. (2016). Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks. CoRR, abs/1511.06448.
- [35] Google Colab, <https://colab.research.google.com/>
- [36] Kaggle, <https://www.kaggle.com/>

- [37] Yan, J., Chen, S., Deng, S.: A EEG-based emotion recognition model with rhythm and time characteristics. *Brain informatics* **6**(1), 7 (2019).
- [38] Xing, X., Li, Z., Xu, T., Shu, L., Hu, B., Xu, X.: SAE+LSTM: A New Framework for Emotion Recognition From Multi-Channel EEG. *Frontiers in Neurorobotics* **13**(37) (2019). doi: 10.3389/fnbot.2019.00037
- [39] Lan, Z., Sourina, O., Wang, L., Scherer, R., Müller-Putz, G. R.: Domain adaptation techniques for EEG-based emotion recognition: a comparative study on two public datasets. *IEEE Transactions on Cognitive and Developmental Systems* **11**(1), 85–94 (2018).
- [40] Bradley, M. M., Lang, P. J.: Measuring emotion: the self-assessment manikin and the semantic differential. *Journal of behavior therapy and experimental psychiatry* **25**(1), 49–59 (1994).
- [41] Duan, R. N., Zhu, J. Y., Lu, B. L.: Differential entropy feature for EEG-based emotion classification. In: 6th International IEEE/EMBS Conference on Neural Engineering (NER), pp. 81–84. IEEE (2013).
- [42] Zheng, W. L., & Lu, B. L.: Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development* **7**(3), 162–175 (2015). doi: 10.1109/tamd.2015.2431497
- [43] Zheng, W. L., Liu, W., Lu, Y., Lu, B. L., Cichocki, A.: Emotionmeter: A multimodal framework for recognizing human emotions. *IEEE transactions on cybernetics* **49**(3), 1110–1122 (2018). doi: 10.1109/TCYB.2018.2797176
- [44] Ganin, Yaroslav et al. “Domain-Adversarial Training of Neural Networks.” *Advances in Computer Vision and Pattern Recognition* (2017): 189–209.