

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО
ПРОФЕССИОНАЛЬНОГО ОБРАЗОВАНИЯ
«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ
«ВЫСШАЯ ШКОЛА ЭКОНОМИКИ»

**Факультет Санкт-Петербургская школа физико-математических и
компьютерных наук**

Багрянова Екатерина Андреевна

**ФОРМИРОВАНИЕ ПРЕДОБУЧЕННЫХ ВЕКТОРОВ ПРИЗНАКОВ
ДЛЯ ОБРАБОТКИ ЭЭГ СИГНАЛОВ В ЗАДАЧАХ**

КЛАССИФИКАЦИИ РАЗЛИЧНЫХ СОСТОЯНИЙ ЧЕЛОВЕКА

Выпускная квалификационная работа - БАКАЛАВРСКАЯ РАБОТА

по направлению подготовки 01.03.02 Прикладная математика и
информатика образовательная программа «Прикладная математика и
информатика»

Рецензент:
старший инженер,
ООО «Манпауэр групп»
Р. К. Григорян

Руководитель:
доктор физико-математических наук,
профессор, департамент информатики
Б. А. Новиков

Консультант:
кандидат технических наук, руководитель лаборатории,
ООО «Техкомпания Хуавэй»
Е. В. Шуранов

Санкт-Петербург
2023

Содержание

Аннотация.....	3
1 Введение.....	5
2 Обзор литературы, подходов и данных.....	9
2.1 Общие модели в области работы с ЭЭГ.....	9
2.2 Wav2vec 2.0 и data2vec 2.0.....	11
2.3 Трансферное обучение.....	11
2.4 Данные.....	12
2.5 Выводы по главе.....	15
3 Техническая часть.....	16
3.1 Код экспериментов.....	17
3.2 Хранение и работа с данными.....	18
3.3 Обучение на облачной платформе.....	19
3.4 Выводы по главе.....	20
4 Группа экспериментов 1. Перенос знаний из звука.....	21
4.1 Описание модели.....	21
4.2 Процесс обучения.....	21
4.3 Полученные результаты.....	22
4.4 Выводы по главе.....	25
5 Группа экспериментов 2. Адаптация модели к ЭЭГ.....	25
5.1 Описание модели.....	26
5.2 Процесс обучения.....	26
5.3 Полученные результаты.....	27
5.4 Выводы по главе.....	30
6 Заключение.....	31
Список литературы (источников).....	33

Аннотация

Современные подходы к решению задач глубинного обучения для различных областей с помощью моделей на основе трансформерной архитектуры заключаются в использовании моделей предобученных на большом количестве данных. Предобученные модели часто превосходят модели, разработанные для решения конкретной задачи. Однако в области работы с ЭЭГ сигналами почти не было проведено исследований в этой области, а также не было разработано эффективной общей модели. В этой работе мы исследуем способы эффективного предобучения трансформера применительно к обработке электроэнцефалограмм. Результатом работы стала общая предобученная модель, которая тестировалась на наборах данных MM1 и Sleep-EDF. Наша модель работает сравнимо с лучшей специальной моделью на наборе данных MM1. На наборе данных Sleep-EDF модель уступает специальной модели, но имеет потенциал для улучшения.

Ключевые слова: ЭЭГ сигналы, предобученная модель, трансформеры, перенос знаний.

Current approaches to solving deep learning problems for various domains using models based on transformer architecture are to use models pre-trained on a large amount of data. Pre-trained models often outperform task-specific models. However, in the field of EEG signal processing, little research has been done in the area of backbone models, and no effective general model has been developed. In this work, we investigate ways to efficiently pre-train the transformer as applied to the processing of electroencephalograms. The result of our work is a pre-trained model for different tasks and datasets that has been tested on the MMI and Sleep-EDF datasets. Our model performed comparably with the SOTA result on the MMI dataset. On the Sleep-EDF dataset, the model is inferior to the SOTA result, but has potential for improvement.

Keywords: EEG signals, pre-trained model, transformers, transfer learning.

1 Введение

В настоящее время остро стоит вопрос об исследовании различных состояний человека. Электроэнцефалография (ЭЭГ) является неинвазивным методом исследования и используется для измерения электрической активности головного мозга. До недавнего времени этот метод использовался только врачами в медицинских кабинетах, в связи с тем, что интерпретация полученных данных проводилась вручную квалифицированным специалистом. Но теперь, благодаря развитию области машинного обучения, мы можем сделать оценку результатов автоматической. Это может упростить и расширить использование данных ЭЭГ в повседневной жизни и медицине.

Для начала разберем, что ЭЭГ данные представляют из себя. Получения данных производится электроэнцефалографом с помощью специальных электродов. Они располагаются на голове пациента. Количество электродов может варьироваться, но часто определяется согласно международным системам “10-20%” или “10-10%”, которые определяют количество и положение электродов относительно друг друга. С каждого электрода мы получаем сигнал с определенной частотой дискретизации. Как результат, можно сделать вывод, что ЭЭГ данные похожи на аудиоданные, потому что мы также получаем сигнал с нескольких каналов. Этот факт важно упомянуть для общего понимания данных, кроме того, он будет использован в дальнейшей работе. Но при работе с ЭЭГ данными необходимо учитывать их некоторые особенности. Во-первых, в силу неинвазивности метода, в данных наблюдаются различные артефакты, такие как моргание, движения глаз или мышц. Во-вторых, ЭЭГ данные могут сильно варьироваться от человека к человеку. В-третьих, хотя клиники регулярно собирают данные у пациентов, не так много данных можно найти в открытом доступе.

В-четвертых, ЭЭГ данные обычно имеют десятки каналов, что заметно больше, чем в звуковых данных.

На основе этих данных можно получать различную информацию о мозговой активности человека и, как следствие, его состоянии. Так мы можем распознавать фазы сна и решать задачу о классификации фаз сна человека, распознавать эмоции и решать соответствующую задачу классификации, распознавать движения и классифицировать их, оценивать уровень вовлеченности, концентрации, рабочей нагрузки и решать задачи, для которых важны эти параметры.

Учитывая характер данных и существующие задачи, подходы к обработке данных ЭЭГ можно разделить на две группы. Первая – это простые модели машинного обучения. Обычно они используются вместе с предварительной обработкой данных, специфичной для ЭЭГ или конкретной задачи, которая заключается в том числе в удалении артефактов. В этой области уже существует множество исследований, и речь не идет об унификации, так как решения обычно специфичны для конкретных задач и наборов данных. Вторая область – глубокое обучение. Этот подход начал использоваться в области ЭЭГ не так давно, после того, как в доступе появились достаточно большие наборы данных, подходящие для работы.

Сейчас в области работы с ЭЭГ данными в основном используются специальные модели, то есть модели, которые решают конкретную задачу на конкретном наборе данных или на группе похожих наборов данных. Так например для задачи детекции фаз сна на наборе данных Sleep-EDF используются модель DeepSleepNet [13], ее более маленькая, но эффективная версия TinySleepNet [14], а лучший результат на этом наборе данных на текущий момент получила модель XSleepNet2 [7].

В то же время, в машинном обучении в целом сейчас наблюдается тренд на более абстрактные модели, которые смогут решать не конкретную задачу на определенном наборе данных, а будут решать группу задач. Такой подход уменьшает количество затраченных ресурсов на разработку и проведение специальных экспериментов, не требует от пользователей моделей постоянно разбираться в тонкостях различных специальных моделей. К тому же, такой подход позволяет агрегировать знания из разных специальных областей и применять их к другим областям. В конце концов, такой подход упрощает решение новых задач – нам не нужно разрабатывать для них специальную модель, мы можем попробовать использовать уже готовую общую модель.

В области ЭЭГ пока не распространен подход создания общих моделей. Единственная модель, описание которой было найдено в статьях и которая позиционировала бы себя как общая модель и решала бы задачи разных типов, оказалась BENDR [4]. Эта модель не получила результаты лучше, чем специальные модели, но авторы сделали шаг в сторону разработки общей модели. Кроме того, эта модель использует трансформеры в ЭЭГ. Это сейчас популярно и активно исследуется авторами в области ЭЭГ [10, 12]. А также модель BENDR имеет потенциал для улучшения. На основе этих фактов было принято решение провести исследования в области создания общей модели для задач классификации состояний на основе ЭЭГ сигналов. Более конкретно, начать создание своей модели с улучшения модели BENDR. Более подробно о BENDR и выбранном подходе будет говориться в следующих разделах.

Цель работы. Целью моей работы было создание модели, предварительно обученной на ЭЭГ данных, чтобы ее можно было использовать на разных наборах данных и задачах, не придумывая для них каждый раз новое специальное решение. Был выбран подход глубинного

обучения поскольку он позволяет нам работать с унификацией и разработать модель, которую можно использовать для разных задач. Кроме того, именно в области глубинного обучения сейчас активно ведутся исследования и получаются перспективные, а где-то лучшие, результаты.

Для достижения цели было принято решение провести группы экспериментов. Под экспериментом мы понимаем запуск конкретного варианта модели на конкретном наборе данных. Группа же экспериментов будет связана общностью модели. То есть обычно в группе экспериментов мы будем использовать одну и ту же модель и запускать ее на разных наборах данных. Всего в работе будет две группы экспериментов. Исходя из цели работы были намечены задачи, которые необходимо решить:

1. Провести обзор статей о работе с ЭЭГ данными и о других областях машинного обучения, выбрать подходы и наборы данных для работы
2. Предложить и реализовать варианты предобучения модели, в том числе улучшая модель BENDR
3. Провести запуски (эксперименты) вариантов предобученной модели на выбранных наборах данных, сравнить свои результаты с результатами других исследователей с помощью подсчета метрик

Профессиональная значимость. Поскольку ЭЭГ является неинвазивным и недорогим методом, работа с сигналами ЭЭГ может быть полезна для разработки новых гаджетов, например, оценивающих уровень концентрации человека. Такие гаджеты могут помочь как в повседневных делах, например, в учебе, так и в более жизненно важных, например, в предотвращении несчастных случаев. Кроме того, если говорить о моей

конкретной задаче, то формирование предобученной модели и получение из нее векторов признаков ускорит, облегчит и унифицирует решение конкретных задач. Также здесь стоит учесть, что эта область недостаточно изучена, о чем говорилось выше.

Остальная часть работы организована следующим образом. В первой главе будет произведен обзор статей, подходов и наборов данных, необходимых для работы. Во второй главе будет описана техническая часть моей работы. Затем будут следовать две главы, каждая из которых будет описывать одну из двух групп экспериментов. В конце будет представлено заключение, в котором будет кратко описана сама работа, полученные результаты и выводы. В самом конце можно будет увидеть список источников.

2 Обзор литературы, подходов и данных

2.1 Общие модели в области работы с ЭЭГ

В области работы с ЭЭГ сигналами существует единственная модель BENDR [4], которая позиционируется как общая модель, которая решает различные типы задач. Другие авторы фокусируются на группе задач или наборов данных, а иногда и одном конкретном наборе данных. Поэтому в этой части работы речь пойдет именно о BENDR.

В статье о модели BENDR авторы предлагают подход для обучения на больших объемах данных ЭЭГ. Метод, описанный в этой работе, состоит из двух основных компонентов: предварительное обучение или предобучение и точная настройка или дообучение. На этапе предварительного обучения происходит обучение модели на большом наборе данных сигналов ЭЭГ TUH-EEG Data Corpus [6] без учителя (о

самом наборе данных речь пойдет позже). Для этого авторы используют подход wav2vec 2.0 [2]. Он заключается в обучении трансформера без учителя и использовании для обучения не только принципа близости, но и принципа различия (на английском языке используется термин Contrastive Learning).

На этапе дообучения модель обучается на более маленьком наборе данных с учителем для решения конкретной задачи. Кроме того, этот этап позволяет оценить качество работы модели с помощью подсчета метрик. Для этого этапа авторы используют разные наборы данных, которые относятся к разным типам задач. В том числе, наборы данных MMI [9] и Sleep-EDF [11], о которых более подробно речь пойдет дальше.

Главной проблемой подхода можно назвать то, что авторы не получают выдающегося результата, который бы превосходил специальные модели для конкретных наборов данных. Но несмотря на этот факт, модель BENDR была выбрана для дальнейшей работы и улучшения по двум причинам.

Во-первых, из найденных мной подходов BENDR является единственной моделью, которая позиционируется как универсальная модель для разных задач ЭЭГ. Остальные авторы, получая многообещающие результаты, фокусируются на конкретных задачах вроде детекции фаз сна, определения эмоций человека или его моторной активности. Эта причина является главной, ведь у нас стоит именно задача построения общей модели.

Во-вторых, трансформеры сейчас используются для решения различных задач в разных областях глубинного обучения и получают отличные результаты. Использование трансформеров в ЭЭГ кажется перспективным. BENDR одна из первых статей, которые используют

трансформеры. После другие авторы показывали эффективность трансформеров для работы с конкретными задачами [10, 12].

2.2 Wav2vec 2.0 и data2vec 2.0

Wav2vec 2.0 [1] и data2vec 2.0 [2] это подходы к обучению трансформера без учителя, которые применяют маскирование. Для понимания этой работы не обязательно углубляться в их устройство, но нужно знать, что data2vec 2.0 помогает решать те же задачи, что и wav2vec 2.0, но имея выигрыш во времени обучения примерно в 10 раз.

Так как авторы BENDR используют в своей работе wav2vec 2.0, сначала мы сохраним этот подход. Затем во второй группе экспериментов мы заменим его на data2vec 2.0 с целью оптимизации затрачиваемых ресурсов на обучение.

Также стоит отметить, что оба подхода имеют разные варианты предобученных моделей. Мы будем использовать базовые варианты, то есть wav2vec 2.0 base и data2vec 2.0 base для звуковых данных. Существуют варианты large, они могут дать лучшие результаты, но требуют больших затрат ресурсов на обучение.

2.3 Трансферное обучение

Несмотря на то, что авторы BENDR используют подход для звука wav2vec 2.0, они обучают свою модель с нуля. В то время как в области машинного обучения сейчас популярен подход трансферного обучения или обучения с переносом знаний. Суть этого подхода заключается в том, что знания, полученные из одной задачи, мы можем попробовать применить к другой задаче, особенно, если эти задачи схожи. В качестве примера можно привести модель в области компьютерного зрения Pix4Point [8].

Авторы использовали веса трансформера для изображений для обработки облаков точек и получили результаты лучше, чем обучение для облаков точек с нуля. Обучение с переносом позволяет нам получить лучшее качество решения задачи с меньшими затратами времени, данных и ресурсов на обучение модели по сравнению с обучением модели с нуля.

В силу схожести аудио и ЭЭГ данных мы можем использовать схожий подход и попробовать применить перенос знаний из звука в ЭЭГ на базе BENDR. А именно, так как авторы BENDR используют подход wav2vec 2.0, для которого существуют предобученные модели для звуковых данных, мы можем попробовать взять веса этих моделей и применить в ЭЭГ.

2.4 Данные

2.4.1 Temple University Hospital Data Corpus

Мы, как и авторы BENDR, работаем с набором данных Temple University Hospital EEG Data Corpus (TUH-EEG) [6], поскольку в настоящее время это самый большой доступный набор данных ЭЭГ. Этот набор данных выбран для части предобучения и будет использоваться для обучения без учителя. Это набор данных больницы Темплского университета представляет собой набор записей ЭЭГ, собранных у пациентов с различными неврологическими расстройствами. Записи являются непрерывными и различаются по продолжительности, некоторые записи длятся несколько часов. Набор данных содержит записи почти 17 000 сессий более чем 10 000 уникальных пациентов. Каждая запись ЭЭГ сопровождается метаданными, включая возраст, пол и диагноз пациента, а также другую дополнительную информацию. У этих данных есть разметка – текстовое описание пациента, его диагноза и лечения. Но мы не

используем эту разметку, так как работаем с набором данных в формате обучения без учителя.

Этот набор данных содержит порядка 1,5 ТБ данных. Мы же будем работать только с частью из них.

2.4.2 MMI

EEG Motor Movement / Imagery Dataset (MMI) [9] мы будем использовать для дообучения и подсчета метрик для обучения с учителем. В этом наборе данных собраны записи длиной одна или две минуты, полученные от 109 волонтеров. Для каждого волонтера имеется 14 записей: одна с закрытыми глазами в покое, одна с открытыми глазами в покое и по 3 записи при выполнении каждого из 4 заданий. Задания заключаются в том, что испытуемый совершает или представляет, что совершает, определенные движения. Мы будем использовать только 12 записей выполнения заданий, как делают авторы BENDR. Классификация будет производиться на 2 класса, в зависимости от того, какие движения совершает испытуемый.

Этот набор данных был выбран для первых экспериментов, так как он небольшой. Кроме того, авторы BENDR тоже его используют, так что мы можем сравнить наши результаты с результатами BENDR при подсчете метрик. В качестве метрики будем смотреть на классическую метрику Ассигасу или точность.

Так как мы хотим сравнить наш результат с другими результатами, полученными на этом наборе данных, будет не лишним провести сравнение со специальными моделями. Самым лучшим решением на этом наборе данных сейчас является EEGNet-based ensemble [3], эта модель

получила результат 0.8636 по метрике ассигасы. Это ансамбль сверточных сетей EEGNet. Сама EEGNet [5] получает результат 0.82.

2.4.3 Sleep-EDF Database Expanded

Набор данных Sleep-EDF мы также будем использовать для дообучения и подсчета метрик при обучении с учителем. В этом наборе данных содержится 197 записей ночного сна, обычно по 2 для испытуемого, но некоторые записи могут быть утеряны или отбракованы. В исследовании принимают участники разных возрастов и полов, также они не принимают медикаменты, влияющие на сон. Несмотря на то, что мы имеем длинные записи ночного сна, работаем мы с отрезками по 30 секунд и классифицируем их на 5 классов: бодрствование, 3 фазы медленного сна и фаза быстрого сна. Этот набор данных уже достаточно большой и также используется авторами BENDR, что позволит нам провести сравнение результатов.

В работе будут использоваться два варианта этого набора данных. Первый будет называться Sleep-EDF, он соответствует описанию выше. Он необходим нам для того, чтобы сравнить свой результат с результатами BENDR, так как они используют именно такой вариант набора данных. Второй вариант будет называться Sleep-EDF±30. Во многих записях в начале и в конце идут длинные этапы бодрствования, из-за этого классы получаются совсем не сбалансированными. Кроме того, обычно при работе с этим набором данных нам интереснее определять фазы сна, а не отделять сон от бодрствования. Так что классическим подходом к работе с этим набором данных является обрезание начала и конца записи, так чтобы с обеих сторон записи осталось не больше 30 минут бодрствования. Набор данных с записями, преобразованными таким образом, мы и будем называть Sleep-EDF±30. Это название используют и другие исследователи,

и такой вариант набора данных необходим нам, чтобы сравнить свое решение с другими подходами.

На Sleep-EDF мы будем считать метрику Balanced Accuracy, так как ее считают авторы BENDR. Она используется для работы с наборами данных с несбалансированными классами и отражает среднее по всем метрикам Recall или полнота, рассчитанным отдельно для каждого класса. На Sleep-EDF±30 будем считать классические метрики для работы с этим набором данных – Accuracy, macro F1-score (среднее по f1-score рассчитанным для каждого класса) и Cohen's kappa, который используется в задачах классификации фаз сна.

Собственно перейдем к значимым подходам и их результатам на этом наборе данных. Если говорить о лучших специальных моделях на этом наборе данных, то тут следует упомянуть лучшее решение, которое использует глубинное обучение – XSleepNet2 [7]. Кроме того, существуют некоторые варианты решений, которые используют только простые модели вроде метода опорных векторов и метода случайного леса и получают лучшие результаты. При этом они уже слишком сильно зависят от предобработки данных и иногда используют сомнительные подходы, например, странные варианты кросс-валидации. Так как есть вопросы к корректности самих методов и сравнения ними, это сравнение было решено оставить за пределами этой работы.

2.5 Выводы по главе

В этой главе были описаны самые важные подходы, которые мы будем использовать в работе, а также наборы данных. На основании этой информации, было принято решение в первой группе экспериментов попробовать улучшить модель BENDR, добавив подход обучения с переносом. А во второй группе экспериментов использовать data2vec 2.0

вместо wav2vec 2.0. Забегая вперед, это будет не единственное отличие двух групп экспериментов, но более подробно об этом будет собственно при описании самих групп экспериментов.

Кроме того, для работы были выбраны наборы данных: TUN-EEG для предобучения и MMI и Sleep-EDF, а также его вариация Sleep-EDF±30 для дообучения. Для наборов данных, участвующих в дообучении, также были выбраны метрики и лучшие специальные модели для сравнения.

3 Техническая часть

Для того, чтобы проводить эксперименты, необходимо было решить несколько технических задач:

1. Реализовать набор классов и функций, из которых можно будет легко собирать необходимые конфигурации экспериментов
2. Организовать хранение данных для обучения, чтобы ими было удобно пользоваться
3. Научиться запускать эксперименты на облачной платформе, предоставляющей видеокарты, научиться быстро разворачивать там окружение, необходимое для работы
4. Научиться логгировать ход и результаты экспериментов

В этом разделе описываются технические решения, которые были приняты в процессе выполнения этой работы.

3.1 Код экспериментов

Первой прикладной задачей была разработка и написание удобной архитектуры для проведения экспериментов. Архитектура, предложенная авторами BENDR, использовала конфиги для проведения экспериментов. Они позволяют быстро поменять какие-то параметры, но все равно не

являются достаточно гибкими – например, нельзя быстро и просто поменять изменяющие части модели и эксперимента. В связи с этим, было принято решение потратить время на разработку удобной и гибкой архитектуры для дальнейшего проведения экспериментов.

В моей работе то, что было в BENDR реализовано в виде конфигов, было заменено на код. Это позволяет проводить более сложные эксперименты, заключающиеся в изменении модели BENDR, более просто и без написания дополнительного кода для парсинга конфигов.

Также в моем коде есть удобная составная модель, которая отвечает требованиям будущих экспериментов. Для их проведения нужно просто поменять какую-то часть модели. С другой стороны, если понадобится что-то более сложное, из большего количества частей, то можно изменить базовый класс и снова использовать уже готовые составные части модели.

Части из BENDR, такие как предобработка данных и части модели, используются из библиотеки авторов BEDNR dn3 как черные ящики. Это значит, что их код никак не меняется и используется для получения конкретного результата, без акцентирования внимания на методах его получения.

3.2 Хранение и работа с данными

Для того, чтобы обучать модели на наборе данных TUN-EEG, необходимо работать с сотнями гигабайтов данных. Для этого был реализован формат хранения ЭЭГ данных на основе библиотеки h5py.

Сначала был создан базовый класс для работы с ЭЭГ данными, который определяет формат их хранения. Он позволяет:

1. Создать новый файл с набором данных, состоящий из необработанных записей ЭЭГ и метайнформации к ним. Метаинформацией могут быть, например, класс этой записи в случае набора данных для классификации.
2. Добавить в существующий файл новую запись.
3. Прочитать из файла нужный отрезок ЭЭГ данных и метайнформацию к ним.

Этот класс был реализовали в работе на основе библиотеки h5py, так как она позволяет удобно хранить числовые данные в виде многомерных массивов на диске по частям, считывая, при обращении к данным, только нужную часть. Эта функция была необходима, так как наборы данных для предобучения не помещались в оперативную память компьютера.

На основе базового класса для ЭЭГ данных были реализованы классы для использования ЭЭГ данных в разных задачах:

1. Класс для предобучения, который выдает отрезки записей ЭЭГ определенной длины
2. Класс для задач классификации, который выдает отрезок ЭЭГ данных и метку его класса, а также поддерживает кросс-валидацию.

Также были реализованы скрипты для скачивания и конвертации всех используемых нами наборов данных в наш формат.

3.3 Обучение на облачной платформе

Для обучения нам необходим был доступ к мощным современным видеокартам, так как обучение моделей на основе трансформеров очень затратно по ресурсам. Свои эксперименты мы проводили на облачной платформе vast.ai, где можно арендовать серверы с видеокартами. Для большинства экспериментов мы использовали видеокарты NVidia RTX

4090, которые являются одной из самых производительных моделей на данный момент.

Для того, чтобы удобно разворачивать окружение, необходимое для работы, на арендованных серверах, мы реализовали скрипты, которые достаточно просто запустить, чтобы получить рабочее окружение.

Для отслеживания процесса обучения и его результатов мы воспользовались облачным сервисом WandB, в который можно посылать различные данные (метрики, значения функции потерь и т.д.), а затем просматривать их в удобном виде. Пример графиков, записанных для эксперимента можно увидеть на рис. 3.1.



Рис. 3.1. Примеры графиков

3.4 Выводы по главе

В этой главе была описана техническая часть моей работы. Несмотря на то, что в начале эксперименты были основаны на модели

BENDR, для удобства использования код был написан с нуля, а части BENDR использовались в некоторых местах как черные ящики. Во время работы приходилось иметь дело с достаточно большими объемами данных, эта проблема была также учтена при реализации. Кроме того, так как модель требовала больших затрат на обучение, эксперименты проводились на облачной платформе. Также было реализовано удобное представление результатов эксперимента в виде графиков.

4 Группа экспериментов 1. Перенос знаний из звука

Несмотря на то, что в статье о BENDR авторы прямо используют подход для звука wav2vec 2.0 и применяют его к похожим на звук ЭЭГ данным, они обучают свою модель с нуля на этапе предобучения. В первой группе экспериментов было решено попробовать не обучать модель с нуля, а использовать уже обученные веса wav2vec 2.0 для звука. Этот подход используется в разных областях машинного обучения и носит название обучение с переносом или трансферное обучение. Подробнее этот подход был описан в секции обзора литературы.

4.1 Описание модели

В этой группе экспериментов наша модель состояла из трех частей. Первая часть – сверточные сети с весами из BENDR, которые авторы получили на этапе предобучения своей модели на датасете TUN-EEG. Вторая – трансформер, инициализированный весами wav2vec 2.0 base для звуковых данных. Третья – классификационная голова, с помощью которой мы будем получать результаты предсказаний на этапе точной настройки.

4.2 Процесс обучения

В этой группе экспериментов мы не будем проводить этап предобучения на большом наборе данных. Вместо этого мы будем работать с имеющимися признаками из моделей BENDR и wav2vec 2.0. Этап дообучения будем проводить на выбранных наборах данных MMI и Sleep-EDF с учителем. При обучении была использована кросс-валидация с разделением на 5 частей и не производились заморозки весов в модели.

Для набора данных Sleep-EDF у нас будет два запуска. Первый будет проведен с такой же предобработкой, как используют авторы BENDR, что позволит нам сравнить наши результаты с их. Второй запуск будет производиться на данных ночного сна с более классической обработкой, формат которых мы называем ± 30 , он был описан в секции с обзором набора данных Sleep-EDF. Этот запуск позволяет нам сравнить свое решение с лучшими специальными решениями в сфере детекции фаз сна и является более “честным”.

4.3 Полученные результаты

Эксперимент был проведен на наборах данных MMI и Sleep-EDF. Для оценки результатов производился подсчет различных метрик. Какие конкретно метрики будут считаться при запуске зависело от того, с какими моделями мы хотим сравнить свой результат и какие метрики считали авторы этих моделей. Так для сравнения с BENDR мы будем считать Balanced Accuracy. А для сравнения с другими специальными решениями мы можем считать Accuracy, macro F1-score и другие.

Для набора данных MMI в таблице 4.1 приведены результаты метрики Accuracy, которая совпадает с Balanced Accuracy, так как этот

датасет сбалансированный. При этом запуске наша модель “перенос знаний из звука” получила результат статистически сравнимый с BENDR.

Таблица 4.1. Результаты модели “перенос знаний из звука” на MMI

MMI	Accuracy
Перенос знаний из звука	0.85 ± 0.01
BENDR	0.84
EEGNet-based ensemble (SOTA)	0.86

Для набора данных Sleep-EDF результаты метрик приведены в таблицах 4.2 и 4.3. В таблице 4.2 приведен запуск модели на наборе данных Sleep-EDF с такой же предобработкой, как используют авторы BENDR. В таблице 4.3 приведен запуск нашей модели на Sleep-EDF±30.

В запуске на Sleep-EDF для сравнения с BENDR производился подсчет метрики Balanced Accuracy, потому что именно ее считали авторы BENDR. Наша модель "перенос знаний из звука" получила результат 0.706, статистически значимо лучше результата BENDR на 1.6%.

Таблица 4.2. Результаты модели “перенос знаний из звука” на Sleep-EDF

Sleep-EDF	Balanced Accuracy	Контекст отрезков
Перенос знаний из звука	0.706 ± 0.003	1
BENDR	0.690	1

В запуске на Sleep-EDF±30 было произведено сравнение с лучшим результатом полученным с помощью глубокого обучения на наборе данных. По результатам метрик наша модель уступает специальной модели. Но, несмотря на это, мы все-таки предлагаем общую модель, так что проигрыш в метрике можно рассматривать как плату за обобщенность модели. К примеру, наша модель никак не привязана к тому, что данные записи сна на самом деле представляют из себя временной ряд.

Если говорить более подробно, то наша модель работает с 30-ти секундными отрезками по отдельности в то время, как специальные модели используют механизмы наподобие рекуррентных сверточных сетей, чтобы учитывать и соседние отрезки для классификации. Этот параметр отражен в соответствующем столбце таблиц 2 и 3. Добавление механизма учета соседних отрезков может улучшить результаты нашей модели.

Таблица 4.3. Результаты модели “перенос знаний из звука” на Sleep-EDF±30

Sleep-EDF ± 30	Accuracy	Macro F1	Cohen's kappa	Контекст отрезков
Перенос знаний из звука	0.796 ± 0.002	0.724 ± 0.002	0.719 ± 0.002	1
XSleepNet2 (SOTA)	0.840	0.779	0.778	20

4.4 Выводы по главе

В этой главе была описана первая группа экспериментов, заключающаяся в переносе знаний из звука. При сравнении нашей модели “перенос знаний из звука” с моделью BENDR был получен статистически сравнимый результат на наборе данных MMI и статистически значимо лучший результат с выигрышем на 1.6% по метрике Balanced Accuracy на наборе данных Sleep-EDF.

Кроме того, было проведено сравнение с лучшими специальными моделями. На наборе данных MMI мы получили результат чуть хуже специальной модели. На наборе данных Sleep-EDF±30 наша модель проигрывает специальной модели XSleepNet2, но зато имеет более общий характер. Также хочется отметить, что для обучения мы использовали базовую версию модели wav2vec 2.0 base, есть еще вариант wav2vec 2.0 large, который может показать лучшие результаты метрики. Но пока такой запуск не проводился в силу долгого процесса обучения и приоритета, отданного другим запускам.

5 Группа экспериментов 2. Адаптация модели к ЭЭГ

В первой группе экспериментов у нашей модели было две части – часть со сверточными сетями, предобученная на ЭЭГ данных, и часть с трансформером, предобученная на звуковых данных (правда самим предобучением мы не занимались и брали готовые веса). Из этого можно сделать вывод, что две части модели не согласованы по данным. Как результат, было предположение, что на этапе дообучения модель может переобучаться раньше, чем успевают сделать части согласованными по данным и эффективно обучиться. Особенно такой эффект может

проявляться на маленьких наборах данных. Во второй группе экспериментов мы будем решать эту проблему и заниматься адаптацией модели к ЭЭГ данным. В целом наша модель будет похожа на модель из первого эксперимента, но мы добавим этап предобучения на большом наборе данных.

5.1 Описание модели

Как и в предыдущей группе экспериментов, модель состоит из трех частей. Первая часть – сверточные сети, но их архитектура отличается от сверточных сетей BENDR и начальные веса берутся случайными. Вторая часть – трансформер. В этой группе экспериментов было решено взять не веса wav2vec 2.0, а веса data2vec 2.0 для звука, так как эти подходы направлены на решение одной и той же задачи, но data2vec 2.0 показывает более хорошие результаты и производительность. Третья часть – снова классификационная голова, которая будет использоваться только на этапе дообучения для получения предсказаний. Отдельно хочется отметить, что в этом эксперименте мы уже никак не используем модель авторов BENDR или ее веса.

5.2 Процесс обучения

В этой группе экспериментов у нас присутствуют оба этапа обучения, то есть и предобучение и дообучение.

В этапе предобучения участвуют только первые две части модели, то есть сверточные сети и трансформер. В качестве начальных весов для сверточных сетей мы берем случайные значения, а для трансформера – значения data2vec 2.0 для звука. Этап предобучения производится на подмножестве набора данных TUH-EEG Data Corpus размером порядка

100 гигабайтов. Само предобучение производится без учителя с помощью метода `data2vec 2.0`.

Кроме того, на этапе предобучения было решено добавить случайное зануление каналов в ЭЭГ данных с помощью слоя Dropout перед сверточной сетью. В этом случае каждый канал ЭЭГ полностью зануляется с определенной вероятностью. Это делается потому, что в разных наборах ЭЭГ данных могут быть представлены разные подмножества каналов, соответственно наша модель должна быть устойчива к этому. Авторы BENDR, как и мы, приводят наши данные к схеме "10-20%", то есть выбирают только часть каналов, а именно 19 штук, из набора данных TUH-EEG Data Corpus. Затем на этапе дообучения наборы данных могут иметь какие-то другие каналы, не совпадающие с этими 19. В таком случае лишние будут удалены, а отсутствующие представлены как канал со всеми нулевыми значениями. Но на этапе предобучения наша модель ничего не знает о таком возможном поведении. Вследствие чего, было принято решение и на этом этапе случайно занулять некоторые каналы.

Этап дообучения максимально схож с составом первой группы экспериментов. За исключением того, что здесь в качестве стартовых весов в сверточных сетях и трансформере мы используем уже свои веса полученные на этапе предобучения. Все три части модели участвуют в обучении, обучение производится с учителем на наборах данных MM1 и Sleep-EDF. Также производится кросс-валидация с разделением на 5 частей и не производится заморозка весов модели.

5.3 Полученные результаты

При запуске на наборе данных MM1 мы получили результат статистически значимо лучше, чем у BENDR, на 2%. Это можно видеть в таблице 5.1. Кроме того, мы улучшили наш предыдущий результат из

первой группы экспериментов. Это и было нашей целью, так как мы предполагали, что из-за несогласованности данных, модель успевает быстрее переобучиться, чем обучиться на ЭЭГ данные. Также наш результат сопоставим с лучшим специальным решением на этом наборе данных.

Таблица 5.1. Результаты модели “data2vec 2.0 на ЭЭГ” на MMI

MMI	Accuracy
data2vec 2.0 на ЭЭГ	0.86 ± 0.01
Перенос знаний из звука	0.85 ± 0.01
BENDR	0.84
EEGNet-based ensemble (SOTA)	0.86

На наборе данных Sleep-EDF был получен результат сопоставимый с результатом в группе экспериментов 1, то есть лучше, чем у BENDR. Это можно увидеть в таблице 5.2.

Таблица 5.2. Результаты модели “data2vec 2.0 на ЭЭГ” на Sleep-EDF

Sleep-EDF	Balanced Accuracy	Контекст отрезков
data2vec 2.0 на ЭЭГ	0.702 ± 0.003	1
Перенос знаний из звука	0.706 ± 0.003	1
BENDR	0.690	1

Соответственно, при сравнении со специальными моделями мы тоже не получили ничего нового, наша модель все так же работает хуже специальной.

Таблица 5.3. Результаты модели “data2vec 2.0 на ЭЭГ” на Sleep-EDF±30

Sleep-EDF ± 30	Accuracy	Macro F1	Cohen's kappa	Контекст отрезков
data2vec 2.0 на ЭЭГ	0.790 ± 0.002	0.716 ± 0.002	0.711 ± 0.002	1
Перенос знаний из звука	0.796 ± 0.002	0.724 ± 0.002	0.719 ± 0.004	1
XSleepNet2 (SOTA)	0.839	0.779	0.778	20

5.4 Выводы по главе

В этой главе была описана вторая группа экспериментов. Она была логическим продолжением первой группы экспериментов, но здесь мы уже полностью ушли от использования частей модели и весов BENDR. Во второй группе экспериментов был добавлен этап предобучения, чтобы согласовать части модели по данным. На этом этапе обучение сверточных сетей происходило с нуля, а для трансформера использовались веса data2vec 2.0 вместо wav2vec 2.0. Это позволило нашей модели учиться быстрее и эффективнее, чем модели BENDR.

На наборе данных MMI мы достигли своей цели – получили статистически значимо лучший результат по сравнению с BENDR на 2%. Кроме того, мы улучшили результат предыдущей группы экспериментов и получили результат, сравнимый с лучшим решением на этом наборе данных. На наборах данных Sleep-EDF и Sleep-EDF±30 результаты остались сопоставимыми с результатами первой группы экспериментов. Это достаточно предсказуемо, так как идеей второй группы экспериментов было добавление части согласования по данным, чтобы на небольшом наборе данных модель не переобучалась слишком быстро, не успевая согласоваться по данным. Кроме того, при сравнении со специальными моделями стоит учитывать, что в нашем решении рассматривается только один временной отрезок, и добавление рассмотрения контекста в нашу модель может улучшить результат.

Также стоит отметить, что отсутствие улучшения на наборе данных Sleep-EDF может обуславливаться тем, что мы недостаточно качественно подобрали вариант предобученной модели. К тому же, это может еще больше улучшить результат на наборе данных MMI. Под недостаточным подбором модели имеется ввиду то, что ее можно обучать с разными

параметрами и останавливать обучение в разные моменты. Затем проводить этап дообучения и сравнивать результаты. К сожалению, это требует огромных временных и ресурсных затрат, так что пока был выбран только один вариант предобученной модели, который хорошо показывал себя по графикам предобучения, для этапа дообучения.

Также стоит учитывать, что мы также взяли базовую версию data2vec 2.0 и только небольшую часть набора данных TUN-EEG Data Corpus опять же в силу огромных затрат ресурсов. Увеличение модели и объема данных на этапе предобучения может улучшить качество решения.

6 Заключение

В ходе работы необходимо было построить общую предобученную модель для решения задач классификации различных состояний человека на основе ЭЭГ данных. Построение такой модели является актуальной задачей, так как в целом в машинном обучении есть тренд на создание общих моделей. Но в ЭЭГ пока существует единственная модель, которая позиционируется как общая – BENDR.

Для достижения цели получения модели был проведен обзор подходов к работе с ЭЭГ и других областей машинного обучения. На основе обзора были выбраны наборы данных для работы – TUN-EEG для предобучения и MMI и Sleep-EDF для оценки качества работы. Также были разработаны две группы экспериментов и получены два варианта предобученной модели – “перенос знаний из звука” и “data2vec 2.0 на ЭЭГ”.

В первой группе экспериментов была разработана модель “перенос знаний из звука”, которая основывалась на BENDR, но для ее улучшения использовалась концепция трансферного обучения. Модель “перенос

знаний из звука” получила статистически значимо лучший результат по сравнению с BENDR на наборе данных Sleep-EDF на 1.6% по метрике Balanced Accuracy.

Во второй группе экспериментов была разработана модель “data2vec 2.0 на ЭЭГ”. Эта модель производила дополнительную адаптацию к ЭЭГ данным и использовала data2vec 2.0 вместо wav2vec 2.0. Модель “data2vec 2.0 на ЭЭГ” получила статистически значимо лучший результат по метрике Accuracy на 2% на наборе данных MMI. Кроме того, этот результат статистически сравним с лучшим специальным решением на этом наборе данных – ансамбле на основе EEGNet.

Если говорить о сравнении наших моделей с лучшим специальным решением на Sleep-EDF, то наши модели получают результат хуже. Это может быть связано в том числе с тем, что наши модели, в отличие от специальных, не учитывают контекст соседних отрезков при классификации. Добавление этой части в наши модели может улучшить результат. Также улучшения результата можно добиться с помощью использования большего количества данных на этапе предобучения и использования трансформерных моделей большего размера (large вместо base)

Список литературы (источников)

1. Baevski, A., Babu, A., Hsu, W., Auli, M. (2022). Efficient Self-supervised Learning with Contextualized Target Representations for Vision, Speech and Language.
2. Baevski, A., Zhou, Y., Mohamed, A., & Auli, M. (2020). wav2vec 2.0: A Framework for Self-Supervised Learning of Speech Representations. *Neural Information Processing Systems*, 33, 12449–12460.
3. Zoumpourlis, G., Patras, I. (2022). Motor Imagery Decoding Using Ensemble Curriculum Learning and Collaborative Training.
4. Kostas, D., Aroca-Ouellette, S., & Rudzicz, F. (2021). BENDR: Using Transformers and a Contrastive Self-Supervised Learning Task to Learn From Massive Amounts of EEG Data. *Frontiers in Human Neuroscience*, 15.
5. Lawhern, V. J., Solon, A. J., Waytowich, N. R., Gordon, S. B., Hung, C. P., & Lance, B. J. (2018). EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces. *Journal of Neural Engineering*, 15(5), 056013.
6. Obeid, I., & Picone, J. (2016). The Temple University Hospital EEG Data Corpus. *Frontiers in Neuroscience*, 10.
7. Phan, H. P., Chen, O., Tran, M. T., Koch, P., Mertins, A., & De Vos, M. (2021). XSleepNet: Multi-View Sequential Model for Automatic Sleep

- Staging. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1.
8. Qian, G., Zhang, X., Hamdi, A., Ghanem, B. (2022). Improving Standard Transformer Models for 3D Point Cloud Understanding with Image Pretraining.
 9. Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering* 51(6):1034-1043, 2004.
 10. Siddhad, G., Gupta, A., Dogra, D. P., & Roy, P. P. (2022). Efficacy of Transformer Networks for Classification of Raw EEG Data. *ArXiv (Cornell University)*.
 11. *Sleep-EDF Database Expanded v1.0.0*. (2013, October 24).
 12. Sun, J., Xie, J., & Zhou, H. (2021). EEG Classification with Transformer-Based Models. In *2021 IEEE 3rd Global Conference on Life Sciences and Technologies (LifeTech)*.
 13. Supratak, A., Dong, H., Li, V. C., & Guo, Y. (2017). DeepSleepNet: A Model for Automatic Sleep Stage Scoring Based on Raw Single-Channel EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11), 1998–2008.

14. Supratak, A., & Guo, Y. (2020). *TinySleepNet: An Efficient Deep Learning Model for Sleep Stage Scoring based on Raw Single-Channel EEG.*