



Известия высших учебных заведений. Прикладная нелинейная динамика. 2025. Т. 33, № 1  
Izvestiya Vysshikh Uchebnykh Zavedeniy. Applied Nonlinear Dynamics. 2025;33(1)

Научная статья  
УДК 004.78

DOI: 10.18500/0869-6632-003126  
EDN: BMEUDZ

## Сравнительный анализ эффективности трансферного обучения по обобщенным данным ЭЭГ для использования в задаче диагностики депрессии

Н. Н. Шушарина

Балтийский федеральный университет имени Иммануила Канта, Калининград, Россия  
E-mail: nshusharina@kantiana.ru

Поступила в редакцию 2.02.2024, принята к публикации 26.06.2024,  
опубликована онлайн 9.10.2024

**Аннотация.** Цель данной работы заключалась в анализе эффективности различных методов глубокого обучения в задаче диагностирования депрессии на основании данных биоэлектрической активности мозга. В частности, изучение потенциала трансферного обучения с использованием искусственной нейронной сети, обученной на значительном объеме обобщенных данных электроэнцефалографии, в целевой задаче диагностики депрессии по сигналам неинвазивной электроэнцефалограммы. **Методы.** В настоящем исследовании использовались такие подходы глубокого обучения, как трансферное и контрастное обучение. Искусственные нейронные сети обучались на открытом наборе данных HBN EO/EC task (The Healthy Brain Network – HBN), содержащем записи сигналов электроэнцефалограммы детей и молодых людей до 21 года с открытыми и закрытыми глазами. В качестве предобученных искусственных нейронных сетей для трансферного обучения использовались архитектуры 1D CNN и EEGNet. С целью проверки качества контрастного обучения набор данных был расширен с помощью аугментации и были отобраны предобученные сети со следующей архитектурой: SimCLR, MoCo, NNCLR, BarlowTwins, DINO. **Результаты.** Было установлено, что архитектура EEGNet, используемая в качестве предобученной сети, в силу своих малых размеров не даёт раскрыть полный потенциал алгоритмов контрастного обучения. EEGNet была заменена на архитектуру 1D CNN с большим числом параметров, что привело к росту показателей качества работы моделей. **Заключение.** Хотя рассмотренный метод трансферного обучения выглядит перспективным, специфичность сигналов электроэнцефалограммы и решаемых на их основе задач требует масштабной адаптации алгоритмов целевой задаче. В случае применения техник контрастной оптимизации для обучения целевой сети это также справедливо. Следует также отметить решающую роль представительности набора данных для обучения предобученной сети, поскольку именно полнота реальных наблюдений увеличивает эффективность аугментации, что приводит к увеличению числа «полезных» признаков в латентном пространстве сети и наилучшим условиям для трансферного обучения в целевой задаче. Если говорить о диагностике депрессии, то в данных должны быть максимально широко представлены примеры электроэнцефалограммы именно пациентов с выраженной депрессией.

**Ключевые слова:** диагностика, депрессия, электроэнцефалография, искусственная нейронная сеть, трансферное обучение, контрастное обучение.

**Благодарности.** Работа выполнена при финансовой поддержке Российского научного фонда (проект № 23-71-30010).

**Для цитирования:** Шушарина Н. Н. Сравнительный анализ эффективности трансферного обучения по обобщенным данным ЭЭГ для использования в задаче диагностики депрессии // Известия вузов. ПНД. 2025. Т. 33, № 1. С. xxx–xxx.  
DOI: 10.18500/0869-6632-003126. EDN: BMEUDZ

Статья опубликована на условиях Creative Commons Attribution License (CC-BY 4.0).

## Comparative analysis of transfer learning performance on generalised EEG data for use in a depression diagnosis task

N. N. Shusharina

Immanuel Kant Baltic Federal University, Kaliningrad, Russia  
E-mail: [nshusharina@kantiana.ru](mailto:nshusharina@kantiana.ru)

Received 2.02.2024, accepted 26.06.2024, available online 9.10.2024

**Abstract.** The purpose of this work was to analyse the performance of different deep learning methods in the task of depression diagnosis based on bioelectrical brain activity data. In particular, to study the potential of transfer learning using an artificial neural network trained on a significant amount of “generalised” electroencephalography data in the task of diagnosing depression from non-invasive electroencephalogram signals. *Methods.* Deep learning approaches such as transfer learning and contrastive learning were used in the present study. Artificial neural networks were trained on the public HBN EO/EC task dataset containing recordings of electroencephalogram signals. The 1D CNN and EEGNet architectures were used as auxiliary artificial networks for transfer learning. In order to test the quality of contrastive learning, the dataset was augmented and the following algorithms were selected as the donor network: SimCLR, MoCo, NNCLR, BarlowTwins, DINO. *Results.* It was found that the EEGNet architecture used as a auxiliary network, due to its small size, does not give the full potential of contrastive learning algorithms. Therefore, EEGNet was replaced by a 1D CNN architecture with a larger number of parameters, which led to an increase in the quality performance of the models. *Conclusion.* Although the considered method of transient learning looks promising, the specificity of electroencephalogram signals and problems solved on their basis requires large-scale adaptation of algorithms and contrastive optimisation techniques for effective training of the target task. It is also worth noting the crucial role of the representativeness of the data set for training the donor network, since it is the completeness of real observations that increases the effectiveness of augmentation, which leads to an increase in the number of “useful” features in the latent space of the network and the best conditions for transfer learning in the target task. If we talk about the diagnosis of depression, the data should maximally represent examples of electroencephalograms of depressed patients.

**Keywords:** diagnosis, depression, electroencephalography, artificial neural network, transfer learning, contrastive learning.

**Acknowledgements.** This work was supported by grant RSF (project No. 23-71-30010).

**For citation:** Shusharina NN. Comparative analysis of transfer learning performance on generalised EEG data for use in a depression diagnosis task. Izvestiya VUZ. Applied Nonlinear Dynamics. 2025;33(1):xxx–xxx. DOI: 10.18500/0869-6632-003126

*This is an open access article distributed under the terms of Creative Commons Attribution License (CC-BY 4.0).*

### Введение

Важной научной задачей, стоящей перед современной биофизикой, цифровой медициной и нейронаукой, является проблема диагностики заболеваний центральной нервной системы по различным модальностям нейровизуализаций с использованием методов искусственного интеллекта и машинного обучения [1, 2]. В настоящее время значительные успехи достигнуты в диагностике эпилепсии [3–5], большого депрессивного расстройства [6–8], аутизма [9, 10], синдрома Ретта [11] и т. д. Наиболее часто в задачах применения методов машинного обучения для медицинской диагностики используются данные функциональной магнитно-резонансной томографии (МРТ) пациентов в состоянии покоя, с использованием которых были достигнуты значительные успехи по применению методов машинного обучения. На основании данных МРТ и алгоритмов глубокого обучения были выявлены цифровые биомаркеры большого депрессивного расстройства [12, 13], болезни Альцгеймера [14, 15] и т. д. Однако для применения в клинической практике особый интерес вызывает использование электроэнцефалографии (ЭЭГ), которая является более простым, дешевым и доступным методом нейровизуализации активности головного мозга пациентов. Сигналы ЭЭГ представляют собой результат измерения электрических потенциалов на коже головы,

Шушарина Н. Н.

поверхности или в глубоких слоях головного мозга. Поскольку потенциал электрода представляет собой лишь обобщенный физический параметр, характеризующий сложные нестационарные электрические процессы в нейронном ансамбле головного мозга, то и полученные данные обладают свойствами нестационарности, нелинейности и негауссности [16], а индивидуальные различия между людьми, особенности их психофизического состояния в момент измерения, специфика применяемого оборудования и постановки электродов приводят к сильным различиям ЭЭГ-сигналов даже для одного и того же события [17]. Дополнительной трудностью, возникающей при анализе ЭЭГ-сигнала с целью извлечения информации, связанной с конкретной задачей, является сильная зашумленность [18].

Трансферное обучение позволяет сохранить и использовать информацию, полученную моделью в аналогичной области, в процессе дообучения на целевой задаче. Эффективность такого дообучения в значительной степени зависит от множества факторов: количества и качества данных для предобученной модели, схожести архитектуры предобученной модели с целевой моделью, структуры и характеристики данных целевой задачи [19, 20].

При использовании трансферного обучения для анализа сигналов ЭЭГ возможно повысить гибкость и адаптивность дообученной модели для разных людей, нивелировать индивидуальные различия респондентов и уменьшить потребность модели в новых данных [21, 22].

Целью данной работы является изучение возможности повторного использования весов искусственной нейронной сети (ИНС), обученной на значительном объеме обобщенных данных электроэнцефалографии в целевой более узкой задаче диагностики депрессии по сигналам неинвазивной ЭЭГ.

## 1. Обзор основных методов

**1.1. Трансферное обучение.** Концепция трансферного обучения заключается, как следует из названия, в переносе («трансфере») информации об обучении, зафиксированной в сети в процессе обучения, в другую сеть. Во всех разновидностях трансферного обучения для этого используется двухэтапная схема, в которой веса сети-классификатора предварительно инициализируют из заранее обученной на большом объеме данных сети, схожей с ней по устройству, а затем дополнительно обучаю уже целевой задаче на отдельном наборе данных. Это оказывается возможным только при схожей структуре данных и архитектуре обеих сетей, поскольку чаще всего сохраняют слои, расположенные ближе ко входу сети. Сохранение весов начальных слоев целесообразно, если предобученная сеть обучалась на значительно большем по размеру наборе данных, поскольку сверточные нейронные сети обладают свойством выделять более общие признаки в первых (входных) слоях, а частные, необходимые для итоговой классификации — в последних (выходных). Полученные общие наборы признаков в виде отдельных экземпляров предварительно обученных сетей достаточно универсальны и часто включаются в стандартные открытые модели, подходящие для широкого круга задач [19]. На момент проведения исследования в открытом доступе отсутствовала предобученная на сигналах ЭЭГ сеть, пригодная для использования, поэтому в ходе работы была смоделирована и обучена на достаточно большом наборе данных HBN сверточная сеть с типичной архитектурой.

Для оценки зависимости эффективности обучения от размера базовой сети в качестве архитектуры предобученных сетей были выбраны компактная сверточная нейронная сеть EEGNet, хорошо зарекомендовавшая себя в задачах классификации ЭЭГ, и сеть 1D CNN с большим количеством параметров.

В выбранном для обучения базовой сети наборе данных HBN разметка представлена в общем виде, но объем данных позволяет преобразовать пространство признаков на втором этапе. Поэтому на вход модели подавался срез ЭЭГ-сигнала, а на выходе был построен классификатор по признакам пола, возраста, закрытые/открытые глаза. Ни один из перечисленных признаков

никак не связан с уровнем депрессии, и пригодность такой обученной сети для использования в целевой задаче заранее неизвестна.

На втором этапе исследования выполняется так называемая «подстройка» (fine tuning) весов сети на отдельном, специфичном для конечной задачи наборе данных, способном представить сети необходимый набор признаков для обучения. При этом дообучение сети затрагивает не все узлы, а лишь дополнительные выходные слои, для которых может применяться отдельная функция ошибки и архитектура. При отсутствии существенной разницы в исходном и целевом доменах метод трансферного обучения глубоких нейронных сетей для анализа сигналов ЭЭГ может заключаться, например, в надстраивании над предобученной сетью нового классификатора или же точной настройке части слоев предварительно обученной модели [19]. В этом случае трансферное обучение модели состоит из предварительного обучения модели связанный задаче, что должно способствовать установке априорных весов модели с последующей адаптацией архитектуры каким-либо способом и обучением целевой задаче с настройкой фиксации уже полученных весов в отдельных слоях [23, 24].

Применительно к сверточным сетям процедура дополнительного обучения целевой задаче может выполняться как для всей сети целиком, так и для части последних слоев, которые в основном ответственны за итоговую классификацию. В данном случае параметры начальных сверточных слоев нейронной сети, выполняющие выделение общих признаков, остаются неизменными («замороженными») во время дополнительного обучения. В литературе описано применение данного метода в прикладных задачах увеличения эффективности интерфейсов «мозг-компьютер» и классификации характерных признаков судорожной активности, а также обнаружение артефактов при анализе инвазивной ЭЭГ [24–27]. Кроме описания прямого переноса весов предобученной сети, встречаются работы, где для обучения используются специальные структуры метрик (представления) [28].

**1.2. Контрастное обучение.** В случае отсутствия предварительной разметки данных или сложности получения качественных данных ЭЭГ применяется другой метод. Он состоит в предварительной подготовке пространства признаков нейронной сети только за счет использования самих данных и называется контрастным обучением, которое может выполняться как с учителем, так и без учителя.

Контрастное обучение без учителя тренирует модель различать схожесть или различие входной пары данных, фиксируя соответствующие признаки в структуре слоев, и успешно применяется для обработки ЭЭГ-сигналов, где предварительно обученная на больших наборах данных модель лучше справляется с шумами, обнаруживает субъектно-независимые признаки и временные зависимости данных [20]. После формирования заранее подготовленного пространства признаков модель лучше выделяет признаки уже в целевой задаче. Метод контрастного обучения демонстрирует хорошие результаты также в задачах компьютерного зрения [29] и обработки естественного языка [30]. Вдобавок предварительное контрастное обучение снижает риск использования артефактов сигнала в качестве признаков и переобучения модели на небольших наборах данных [31]. Важным компонентом, определяющим эффективность базовой сети после применения контрастного обучения, является выбор алгоритма оптимизации сети, включая определение метрик схожести латентных представлений сигналов и особенности конструирования негативных пар. Последнее особенно важно, так как ограничение обучения только позитивнымиарами приводит к коллапсу латентного пространства (mode collapse), при котором сеть представляет все сигналы как одинаковые. Насколько сигналы отличны, заранее неизвестно, и некорректное назначение негативных пар, составленных из схожих между собой сигналов, дестабилизирует процесс обучения.

Для задачи сравнения эффективности были подобраны алгоритмы контрастного обучения, хорошо зарекомендовавшие себя в задаче классификации изображений и адаптированные для работы с модифицированной архитектурой сверточных сетей.

В литературе описано несколько реализаций алгоритмов контрастного обучения, каждый со своими преимуществами и недостатками. Из-за специфики решаемой задачи выбор наилучшего алгоритма затруднен, и необходимо сравнительное тестирование.

Фреймворк контрастного обучения SimCLR [32] часто используется в качестве базового при разработке новых контрастных алгоритмов, поскольку на практике негативные пары обычно конструируются по каждомуциальному отдельному батчу (пакету данных для обучения, подаваемому на вход модели за итерацию, после которой выполняется обновление параметров модели). При этом допускается, что каждый пример данных в отдельном батче считается отличным от других. В SimCLR устанавливается ряд эвристик, полезных для обучения.

- Для выделения латентных представлений используется модуль энкодера в виде нескольких полносвязных слоёв с ReLU-активацией, который применяется только при обучении и служит для связи между базовой сетью и контрастной целевой функцией.
- В качестве оптимальной целевой функции применяется категориальная перекрёстная энтропия при условии предварительной нормализации латентных векторов и использовании температурного масштабирования (temperature scaling) для выходного распределения весов сети.
- Размер батча должен быть максимально большим для генерации максимального числа негативных пар.
- Косинусный коэффициент, рассчитываемый для пар в качестве метрики «схожести» сигналов, должен стремиться к нулю для негативных и к единице для позитивных пар сигналов.
- Многопараметрические сети лучше приспособлены для контрастного обучения, при этом эффективнее не добавление новых слоев, а увеличение количества нейронов в слое.

В алгоритме MoCo [33] для снижения зависимости от размеров батча и общего повышения стабильности при конструировании контрастных пар использован принцип динамического словаря, в котором запросом считается отдельный сигнал, а ключами — остальные примеры для представления позитивных и негативных пар. При таком подходе размер батча определяется только количеством запросов, а ключи выбираются из очереди. Запросы генерируются сетью самого фреймворка, а ключи — ее копией с медленно обновляемыми параметрами. Алгоритм, таким образом, больше не зависит от размера батча и количества негативных пар и может применяться для относительно небольших наборов обучающих данных. Вдобавок появляется своеобразное смещение обучения в сторону плавного обновления весов, что увеличивает стабильность. Резкие изменения не отражаются в кодирующем ключи копии, что приводит к повышению сложности и штрафуется в процессе оптимизации.

В алгоритме NNCLR [34] принцип динамического словаря конструирования пар с помощью ключей применяется для позитивных пар. Для каждого сигнала-запроса батч доукомплектуется «схожими» парами из динамического словаря, определяемыми с использованием алгоритма ближайших соседей. Контрастирование осуществляется на более высоком семантическом уровне, а эффективность обучения в меньшей степени зависит от качества процедуры аугментации при достаточно стабильном процессе оптимизации.

BarlowTwins [35] представляет собой модернизированный алгоритм SimCLR с использованием взаимной корреляции вместо косинусного коэффициента и добавлением собственной двухкомпонентной целевой функции вместо категориальной перекрёстной энтропии для уменьшения зависимости от размеров батча и эффективного использования латентного пространства признаков. Первый компонент функции приблизительно соответствует обычному контрасту, оптимизируя «близость» позитивных пар по метрике корреляции, а второй служит для уменьшения избыточности в элементах латентных векторов и уменьшения количества повторений.

В алгоритме контрастного обучения DINO [36] используются только позитивные пары. Выполняется оптимизация между обучаемой сетью (учеником) и её медленно обновляемой копией (учителем). Обе эти сети обучаются по аналогии с алгоритмом MoCo, а целевая функция

представлена перекрёстной энтропией между учеником и учителем. Таким образом, в DINO сравнивается схожесть латентных представлений примеров данных в двух сетях. Из-за отсутствия негативных пар ухудшается стабильность обучения, и авторы рекомендовали выполнять декоррелирующее преобразование латентных векторов.

В данной работе были использованы реализации описанных выше алгоритмов из публичного репозитория фреймворка контрастного обучения для классификации изображений с использованием Keras [37]. В целях сохранения возможности сравнения полученных результатов работа с данными и вспомогательные функции оптимизации полностью идентичны в обоих вариантах трансферного обучения, а последовательное обучение моделей выполнялось с одинаковой базовой сетью на всех основных алгоритмах.

## 2. Наборы данных

**2.1. Вспомогательный набор данных для обучения базовой сети.** В качестве набора данных для предобученной сети был выбран самый большой из доступных, близких к задаче диагностики депрессии открытый набор данных HBN EO/EC task [38], в силу большого количества участников и значительного размера (2952 записи ЭЭГ детей от 5 лет до 21 года с открытыми и закрытыми глазами), а также схожести структуры данных с целевой задачей. Данные каждого участника представлены в виде 5 отрезков, состоящих из записи длиной 20 секунд с открытыми глазами и 40 секунд с закрытыми глазами. В описательном файле набора данных для каждого участника содержится следующая информация: пол (булевая переменная — мужчина / женщина), возраст (число с плавающей запятой — количество лет), ведущая рука (число с плавающей запятой — на шкале левша / правша). Данные о ведущей руке в работе не использовались.

Подробные данные о наборе данных HBN EO/EC task приведены в табл. 1.

Таблица 1. Описание набора данных ЭЭГ HBN EO/EC task  
Table 1. HBN EO/EC task EEG dataset description

<b>Название</b>	HBN EO/EC task
<b>URL</b>	<a href="https://openneuro.org/datasets/ds004186/">https://openneuro.org/datasets/ds004186/</a> versions/2.0.0
<b>Место получения</b>	Институт нейронных вычислений, Университет Калифорнии, Сан-Диего, США
<b>Общее число участников</b>	2952
<b>Число мужчин/женщин</b>	1046/1906
<b>Средний возраст, лет</b>	10.3 ± 3.5
<b>Используемые каналы ЭЭГ</b>	HydroCel Geodesic Sensor Net. Каналы, соответствующие системе 10–10: C3, C4, Cz, F3, F4, F7, F8, FP1, FP2, Fz, O1, O2, P3, Oz, P4, P7, P8, T7, T8, AF3, AF4, AF7, AF8, AFz, C1, C2, C5, Pz, C6, CP1, CP2, CP3, CP4, Cp5, CP6, CPz, F1, F2, F5, F6, F9, F10, FC1, FC2, FC3, FC4, FC5, FC6, FCz, FT10, FT7, FT8, FT9, P1, P2, P5, P6, P9, P10, PO3, PO4, PO7, PO8, POz, T9, T10, T11, T12, TP7, TP8, TP9, TP10
<b>Референс</b>	Cz
<b>Частота дискретизации, Гц</b>	500
<b>Параметры фильтрации (ФВЧ/ ФНЧ/режекция), Гц</b>	нет данных
<b>Формат файлов данных</b>	.set, .fdt (EEGLAB)

Для дальнейшей работы данные ЭЭГ были предварительно обработаны согласно ранее разработанной процедуре с использованием библиотеки MNE-Python [39]:

- 1) снижение частоты дискретизации до 200 Гц;
- 2) цифровая фильтрация сигнала ФВЧ (1 Гц), ФНЧ (40 Гц), режекторный фильтр (60 Гц);
- 3) выбор 19 отведений: Fp1, Fp2, F7, F3, Fz, F4, F8, T7, C3, Cz, C4, T8, P7, P3, Pz, P4, P8, O1, O2, соответствующий стандартной ЭЭГ-системе 10–20;
- 4) приведение к единому названию и порядку каналов, сохранение полученных данных в файлах формата CSV и HDF5.

**2.2. Основной набор данных для классификации депрессии.** На момент проведения исследования были найдены следующие доступные наборы данных, содержащие данные ЭЭГ пациентов с диагностированным депрессивным расстройством и полученные в расслабленном состоянии с закрытыми глазами:

- 1) MDD Patients and Healthy Controls EEG Data (New) [40];
- 2) EEG: Depression rest [41];
- 3) MODMA Dataset: a Multi-modal Open Dataset for Mental-disorder Analysis [42].

Первый и второй наборы данных доступны для скачивания в сети Интернет. Для получения доступа к третьему набору данных необходимо было заполнить и отправить авторам Лицензионное соглашение конечного пользователя.

Для дополнения открытых наборов данных для классификации депрессии и увеличения общего количества наблюдений и пациентов было проведено исследование ЭЭГ у 37 пациентов (9 мужчин, 28 женщин, средний возраст –  $39.8 \pm 15.2$ ) с подтвержденным диагнозом депрессивного расстройства на базе Клинико-диагностического центра БФУ им. И. Канта.

В ходе сессии проводилась регистрация ЭЭГ бодрствующих пациентов в расслабленном состоянии с закрытыми и открытыми глазами.

Как видно из табл. 2, общие свойства наборов данных значительно различаются, но для создания итоговой базы данных ЭЭГ необходимо объединить.

Таблица 2. Параметры наборов данных ЭЭГ, связанных с депрессией  
Table 2. Parameters of EEG datasets associated with depression

	Наборы данных				
<b>Источник</b>	[40]	[41]	[42]	Данная работа	TDBRAIN
<b>Источник данных</b>	Малайзия	США	Китай	Россия	Нидерланды
<b>Общее число участников</b>	64	121	53	37	1274
<b>Число участников с БДР</b>	34	46	24	27	320
<b>Диагностика БДР</b>	Диагноз	Диагноз, шкала Бека	Диагноз	Диагноз, шкала Бека	Диагноз, шкала Бека
<b>Число мужчин / женщин</b>	38/26	47/74	33/20	9/28	654/620
<b>Средний возраст, лет</b>	$39.4 \pm 14.1$	$18.9 \pm 1.2$	$31.2 \pm 9.6$	$39.8 \pm 15.2$	$38.7 \pm 19.2$
<b>Число каналов</b>	19	66	129	19	33 (26)
<b>Частота дискретизации, Гц</b>	256	500	250	500	500
<b>Параметры фильтрации (ФВЧ/ФНЧ /режекция), Гц</b>	0.1/70/50	нет данных	нет данных	0.5/70/50	/100/
<b>Референс</b>	Linked ear (LE)	Между Cz и CPz	Cz	A1	Между A1 и A2

Для согласования данных использовалась следующая процедура с использованием библиотеки MNE-Python:

- согласование частоты дискретизации с понижением до 200 Гц;
- применение цифровых фильтров согласно принятой практики ФВЧ (1 Гц), ФНЧ (40 Гц) [9];
- согласование числа используемых каналов до 19 отведений, используемых в нашей настройке сбора данных: Fp1, Fp2, F7, F3, Fz, F4, F8, T7, C3, Cz, C4, T8, P7, P3, Pz, P4, P8, O1, O2);
- изменение референсного электрода на Cz во всех наборах данных;
- приведение к единому виду и формату размерности данных, названий и порядка каналов, преобразование файла для сохранения результатов в формат CSV.

Каждый полученный файл данных был размечен меткой наличия или отсутствия БДР (большого депрессивного расстройства). В случае отсутствия данных о наличии диагноза метка наличия БДР назначалась для пациентов с результатом теста по шкале Бека выше 13 баллов. Для контроля качества полученных данных каждый файл данных был визуально исследован с отбором наибольшего непрерывного участка данных без существенных артефактов и отбрасыванием зашумленных сегментов.

Промежуточный объединённый набор данных ЭЭГ пациентов в расслабленном состоянии с закрытыми глазами, размеченный в соответствии с наличием или отсутствием БДР, содержит данные 122 пациентов с диагнозом БДР и 123 файлов контрольной группы суммарной продолжительностью 13927 и 13841 секунд соответственно.

Позднее созданная объединенная база данных ЭЭГ, размеченная в соответствии с наличием или отсутствием БДР, была дополнительно расширена за счет большого открытого набора данных TDBRAIN [43]. Сводные данные об основных характеристиках наборов данных приведены в табл. 2.

Число пациентов с меткой диагноза БДР в наборе данных TDBRAIN составляет 320 человек, с меткой «Здоров» — всего 47 человек, что потребовало дополнительного отбора пациентов с метками «Синдром дефицита внимания и гиперактивности», «Обсессивно-компульсивное расстройство» и «Тиннитус» в количестве 200, 40 и 31 человек соответственно для балансировки классов и назначения им метки депрессии, поскольку данные расстройства часто являются сопутствующими при депрессии и приводят к схожему нарушению психофизиологического состояния.

Таким образом, итоговый размер объединенной базы данных ЭЭГ пациентов в расслабленном состоянии с закрытыми глазами: 441 файлов пациентов с диагнозом БДР и 443 файлов пациентов контрольной группы. Суммарная продолжительность сырых сигналов ЭЭГ составила 52144 и 51968 секунд соответственно.

**2.2.1. Выбор частот фильтрации.** При использовании стандартных методов клинической интерпретации данных ЭЭГ рассматриваются сигналы, находящиеся в диапазоне частот 0.1...70 Гц. В случае исследований диагностики депрессии по данным ЭЭГ наиболее распространенный диапазон частот уже и составляет 1...40 Гц. Именно этот диапазон и применялся при цифровой фильтрации сигналов в объединенном наборе данных после понижения частоты дискретизации до 200 Гц.

Дополнительных методов удаления артефактов, кроме проведения визуальной инспекции, не применялось, так как у людей, находящихся в расслабленном состоянии и с закрытыми глазами, предполагается минимизация мышечной активности и отсутствие артефактов моргания и движения глаз.

**2.2.2. Анализ эффективности гармонизации.** Очевидно, сырой ЭЭГ-сигнал в чистом виде не подходит для анализа структуры полученного набора данных в силу большого числа переменных (порядка нескольких тысяч) и необходимо воспользоваться теорией представлений.

С использованием представлений выполняется преобразование исходных данных для снижения числа независимых переменных до двух или трех, что удобно для визуализации и анализа человеком. В качестве примера таких преобразований можно привести метод случайных проекций и метод главных компонент (PCA), но для визуализации данных ЭЭГ целесообразно использовать метод стохастического вложения соседей с t-распределением (t-SNE) [44], широко распространенный в области низкоразмерной визуализации многомерных данных. В отличие от PCA, который стремится сохранить глобальную структуру данных, t-SNE сохраняет только локальную структуру (смежность ближайших соседей точек выборки). Это означает, что при интерпретации полученных данных ни размер, ни глобальное расположение отдельных кластеров не несут полезной информации, а интерпретируемым признаком является равномерность распределения по классам.

Для обработки данные нарезались скользящим окном с шагом 0.5 секунд на сегменты длиной 3 секунды, затем для каждого окна с помощью преобразования Фурье рассчитывался спектр мощностей и производилась нормализация данных таким образом, чтобы среднее по окну равнялось нулю, а дисперсия — единице. Подготовленные данные подавались на вход t-SNE (реализация sklearn) при различных значениях параметра перплексии в диапазоне от 5 до 50. Результаты дополнительно размечались цветом в соответствии с источником данных и поставленным диагнозом. Полученная низкоразмерная проекция набора данных представлена на рис. 1 и 2.

При варьировании перплексии в выбранном диапазоне существенных структурных преобразований полученного представления не наблюдалось, что позволяет предположить адекватность

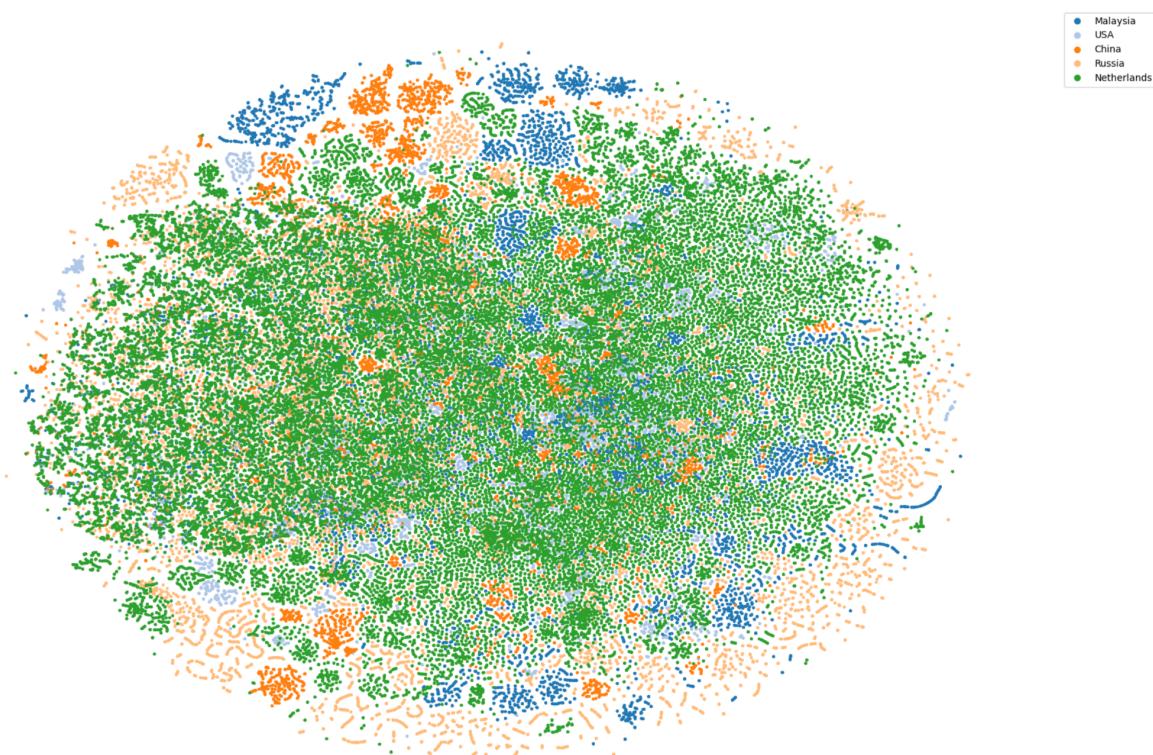


Рис. 1. Результаты t-SNE (перплексия 25), цветовая индикация согласно источнику данных (цвет онлайн)

Fig. 1. Results of t-SNE clusterisation (perplexion 25), color code means data source (color online)

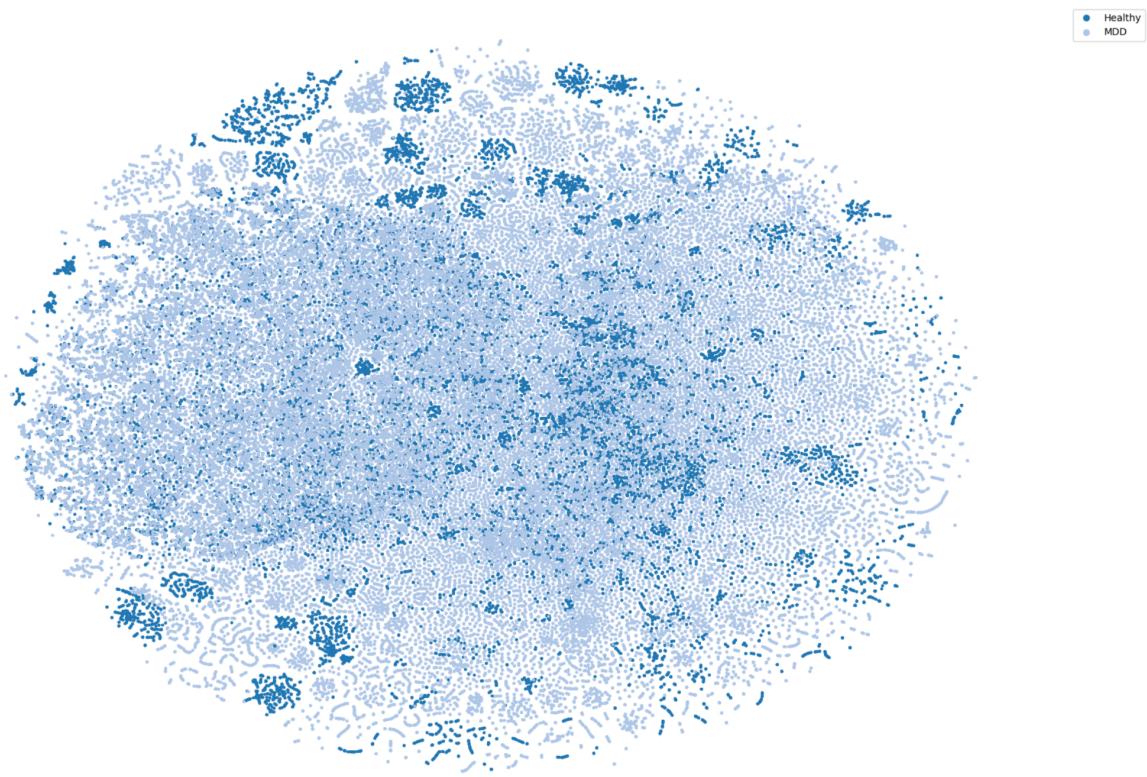


Рис. 2. Результаты t-SNE (перплексия 25), цветовая индикация согласно поставленному диагнозу (цвет онлайн)

Fig. 2. Results of t-SNE clusterisation (perplexion 25), color code means diagnosis labeling (color online)

построенной проекции и свидетельствует в том числе, что полученные кластеры не являются фиктивными.

Рассмотрение полученного распределения по источникам данных позволяет сделать вывод об успешности выбранной процедуры гармонизации выборок. Данные не распадаются естественным образом на крупные кластеры, значительная часть сосредоточена в центральном скоплении, состоящем из данных всех начальных наборов. На периферии можно наблюдать несколько малых кластеров, отличающихся как по источнику данных, так и по диагнозу. Длинные цепочки точек — предположительно восстановленные алгоритмом целиком сессии записи данных отдельных пациентов. Распределение по диагнозу также не показывает очевидного разделения. Резюмируя, можно сделать вывод о том, что созданный набор данных соответствует задаче исследования и подходит для обучения на нем основной нейронной сети.

**2.3. Аугментация.** Для увеличения объема данных обучения и внесения наблюдений, незначительно различающихся между собой, используется аугментация, то есть преобразование отдельных характеристик сигнала по определенным шаблонам. За счёт многообразия вариантов аугментаций возникает индуктивное смещение, расширяющее охват потенциальных признаков полезного сигнала. Хотя отдельные признаки могут быть инвариантны к некоторым типам аугментации и являться индикаторами схожести для контрастных пар, но не существует признака, инвариантного к любым изменениям сигнала (при условии надлежащим образом заданной процедуры аугментации) [20, 22]. Данный эффект приводит к тому, что сеть обучается различать множество различных признаков, никак не ограниченных рамками конкретной задачи и зависящих только от полноты набора применяемых аугментаций и наличия паттернов в обучающей выборке.

В данном исследовании используется работа [31], посвященная анализу ЭЭГ-сигналов, связанных с нейрофизиологическими процессами внимания и кратковременной памяти. Влияние кратковременной памяти на когнитивные функции пациентов хорошо известно, поэтому можно предположить, что приведённый в статье набор аугментаций позволит получить эффективный набор синтетических данных. Список рекомендованных авторами аугментаций следующий:

- добавление Гауссова шума,
- зануление сигнала по всем каналам на случайном отрезке произвольной длины,
- сдвиг среднего значения на произвольном канале,
- зануление сигнала для нескольких произвольных каналов,
- изменение знака сигнала на противоположный на произвольных каналах,
- полосно-заграждающая фильтрация на случайной полосе частот в сигнале,
- масштабирование амплитуды сигнала,
- масштабирование амплитуды сигнала с использованием кубического сплайна.

Все вышеуказанные пункты, за исключением последнего, для которого не были приведены детали реализации, вошли в финальную процедуру аугментации. В ней пример данных дважды проходит через конвейер аугментаций, каждая из которых применяется с вероятностью 75%. Полученный сигнал образует позитивную пару наблюдений, внутренние представления которых должны размещаться вблизи друг друга в латентном пространстве обученной сети. Данный алгоритм был внедрен в конвейер обучения базовой сети на первом этапе.

### 3. Методика обучения и обработки данных

**3.1. Методика обучения предобученной сети.** В качестве базовых архитектур предобученных сетей применялись сверточная нейронная сеть EEGNet, хорошо зарекомендовавшая себя в задачах классификации ЭЭГ, и сеть архитектуры 1D CNN с большим количеством параметров. Для обучения был подобран следующий алгоритм переноса части обученных слоев:

- от исходной сети отделялись все полносвязные слои, прилегающие к выходному слою;
- для каждого из целевых признаков создавался полносвязный перцептрон с двумя скрытыми слоями (с двумя выходными нейронами в случае булевой целевой переменной и одним в противном случае);
- вход каждого перцептрана соединялся с новым выходным слоем исходной сети.

Таким образом, для предобученной сети использовались 3 выхода (пол, возраст, закрытые/открытые глаза), соответствующие разметке базового набора данных, напрямую не связанного с депрессией. Это позволило оценить эффективность обучения сети в целом перед дополнительным обучением на целевом наборе данных.

Основные параметры вспомогательных сетей приведены в табл. 3.

Таблица 3. Основные параметры вспомогательных сетей

Table 3. Pre-trained CNN parameters

Сеть	Количество слоев	Количество нейронов в скрытых слоях	Количество ядер	Функция активации	Количество параметров
CNN 1D	5	100/5	128	RELU	12170105
EEGNet	11	10/10	16	Линейная	3685

При обучении использовалась специально построенная функция потерь, представляющая собой взвешенную сумму функций потерь для каждого отдельного выхода (среднеквадратичная ошибка для возраста и бинарная перекрестная энтропия для остальных). При обучении модели веса подбирались таким образом, чтобы функция потерь была минимальна.

После обучения с использованием алгоритма Adam с шагом  $10^{-5}$  для проверки качества обучения на тренировочной выборке вычислялись точности по каждому классу (пол, закрытые/открытые глаза) и среднеквадратичная ошибка (возраст) соответственно.

Данные для обучения подготавливались следующим образом:

- нарезка скользящим окном длиной 4 секунды с шагом 2 секунды,
- фильтрация режекторным фильтром 60 Гц и полосовым 0.5...100 Гц,
- нормализация данных на 0 среднего и 1 дисперсии.

После подготовки данные были разделены на обучающую и тестовую выборки в соотношении 9 : 1, при этом ни один субъект не попадал в обе выборки одновременно для предотвращения утечки данных. Для обучения на латентном пространстве признаком применялась аугментация данных в виде позитивным пар.

Результаты обучения на базовом наборе данных показали достаточно хорошие результаты. Так, обе архитектуры сети показали точность более 0.8 (1D CNN – 0.82, EEGNet – 0.81) в задаче определения пола, более 0.7 (1D CNN – 0.81, EEGNet – 0.74) в задаче определения открытых или закрытых глаз. Задача определения возраста показала существенное различие в результатах обучения. Так, среднеквадратичная ошибка для EEGNet составила 15.69, а для 1D CNN – 6.07. Несмотря на некоторую разницу результатов, обе сети пригодны для дальнейшего обучения на целевом наборе данных для классификации депрессии.

**3.2. Методика обучения основной сети.** Используя полученные базы данных ЭЭГ-сигналов, были выполнены процедуры обучения двух рассмотренных выше нейронных сетей и урезанной сверточной сети, схожей с EEGNet.

1. Одномерная сверточная нейронная сеть из 5 слоев (CNN 1D) [45].
2. Компактная двумерная сверточная нейронная сеть из 11 слоев (EEGNet) [46].
3. Двумерная сверточная нейронная сеть из 8 слоев (CNN 2D), созданная по принципу EEGNet, но состоящая только из сверточных слоев.

Перед обучением выполнялась следующая подготовка данных:

- 1) загрузка данных из CSV-файла;
- 2) нарезка данных на отрезки по 600 отсчетов без перекрытия (соответствует продолжительности сигнала в 3 секунды);
- 3) нормализация данных путем сдвига несущей таким образом, чтобы среднее значение входной переменной было близко к нулю, а ковариация данных – приблизительно одинакова по всей обучающей выборке для увеличения скорости сходимости при обучении [47–51].

С целью получения достоверных результатов разбиение данных осуществлялось с учетом их принадлежности конкретному пациенту, а само обучение велось с использованием процедуры перекрестной проверки, которая состоит в разбиении данных на 10 непересекающихся частей с последовательной проверкой эффективности обучения на разных распределениях обучающей и тестовой выборок со стратифицированным разбиением. По результатам обучения для каждого разбиения вычислялись значения точности классификации и F1-меры.

В качестве обучающего алгоритма использовался метод аддитивной инерции (Adam) с параметрами скорости обучения 0.0001 и размером минибатча 64. Используемая функция потерь – стандартная категориальная перекрестная энтропия. Обучение сети происходило с отслеживанием динамики изменения функции ошибки на тестовой выборке (с использованием функции EarlyStopping из библиотеки TensorFlow) и останавливалось при отсутствии улучшения функции ошибки в течении 4 эпох.

Итоговое обучение нейронных сетей, предварительно обученных на наборе данных HBN EO/EC task, выполнялось по следующей процедуре:

1. Загрузка предварительно обученной нейронной сети.
2. Отбрасывание последних полносвязных слоев, отвечающих за классификацию или регрессию на целевые данные вспомогательной задачи.
3. Добавление новых полносвязных слоев, предназначенных для решения задачи классификации депрессивного расстройства.
4. Обучение сети на данных ЭЭГ пациентов с депрессией с пониженнной скоростью обучения (0.00001).

В случае контрастного предварительного обучения этапы были аналогичны, но веса предварительно обученной нейронной сети были фиксированы и не менялись в процессе обучения.

Результаты усредненных данных перекрестных проверок о точности классификации и F1-меры представлены в табл. 4.

Полученные результаты демонстрируют, что ни изменение частот фильтрации, ни трансферное обучение с аугментацией не способствовали существенному повышению точности классификации депрессии в целевой задаче. Использование архитектуры EEGNet в 2D представлении из одних лишь сверточных слоев также оказалось безуспешным. При этом существенной разницы в точности не удалось достичь также для контрастного обучения на обеих архитектурах сетей. Несколько более высокие результаты для сети 1D CNN объясняются скорее большим количеством настраиваемых параметров, нежели успешным выделением признаков депрессии. Так как набор данных для контрастного обучения был составлен из записей ЭЭГ детей без диагностированной депрессии, никакой первичной информации о конечной задаче диагностики в нем не содержалось. Увеличение размеров предобученной сети позволило получить в достаточной степени качественное латентное пространство в контексте решаемой задачи при сохранении структуры и числа обучаемых весов блока классификации, но полученные результаты сопоставимы с показателями EEGNet, напрямую обученной на задачу диагностики депрессии. Это позволяет предположить успешное выделение широкого спектра релевантных паттернов ЭЭГ обеими сетями, но без привязки к каким-либо узконаправленным задачам. При этом их латентные представления сырых сигналов являются достаточно эффективными, чтобы выступать в качестве признаков, позволяющих более компактной по размерам сети достичь для рассматриваемой задачи результатов, сопоставимых с результатами оригинальной EEGNet при прямом обучении без трансфера. Необходимо отметить, что из-за особенностей конструкции трансферных моделей дальнейшие изменения в модуле классификации ситуацию изменить не могут, поскольку достигнутые показатели точности практически полностью зависят от качества выделяемых паттернов ЭЭГ.

Таблица 4. Точность классификации депрессивного расстройства по данным ЭЭГ нейронными сетями на разных версиях базы данных ЭЭГ и использованием трансферного обучения

Table 4. Depression classification accuracy based on transfer learning models using different EEG datasets

Фильтрация ЭЭГ от 1 до 40 Гц						
Обучение	Предобученная		Без предобучения			
Сеть	CNN 1D	EEGNet	CNN 1D	EEGNet	CNN 2D	
<b>Точность</b>	0.64 ± 0.04	0.66 ± 0.05	0.65 ± 0.05	0.66 ± 0.05	0.65 ± 0.04	
Фильтрация ЭЭГ от 0.5 до 100 Гц						
Обучение	Предобученная			Без предобучения		
Сеть	CNN 1D	EEGNet	CNN 1D (MoCo)	CNN 1D (SimCLR)	CNN 1D	EEGNet
<b>Точность</b>	0.66 ± 0.04	0.65 ± 0.05	0.66 ± 0.04	0.66 ± 0.04	0.66 ± 0.05	0.66 ± 0.06
					0.65 ± 0.05	

Для проведения сравнительного анализа влияния размера моделей было выполнено дополнительное обучение на целевом наборе данных двух архитектур сетей с заявленными высокими показателями в целевой задаче диагностики депрессии: DeprNet и DepHNN.

- Сеть DeprNet [53] — глубокая (18 слоев) одномерная сверточная сеть с заявленной точностью классификации депрессии 99.37%. Содержит сверточные слои (320 ядер 1x5) и классификатор в виде 3 полносвязных слоев (16, 8 и 2 нейрона).
- Сеть DepHNN [54] — гибридная (6 слоев) сеть из одного одномерного сверточного слоя и слоев LSTM с заявленной точностью классификации депрессии 99.10%. Содержит 64 ядра 1x5 в одном сверточном слое, два слоя LSTM (64 и 32) и аналогичный сети DeprNet классификатор из трех полносвязных слоев в 16, 8 и 2 нейрона.

Результат обучения на полученном целевом наборе данных показал:

- DeprNet:  $0.65 \pm 0.04$ ;
- DepHNN:  $0.65 \pm 0.03$ .

Полученные результаты резко отличаются от приведенных в работах [53, 54] и в целом аналогичны полученным при трансферном обучении на сетях с предыдущими вариантами архитектуры. Это позволяет утверждать, что причина кроется не в архитектуре сетей как таковой, а скорее в методе обучения и структуре обучающих данных в целом. Учитывая разнородность источников получения данных, объединенных в одну выборку, и сравнительно небольшое количество информации о каждом конкретном пациенте, представленной в ней, можно предположить наличие множества различных признаков депрессии, отличающихся у разных пациентов. Это также приводит к гипотетической возможности достижения высокой точности классификации за счет некорректного разбиения данных (без учета разделения данных по пациентам) на существенно меньших выборках (менее 50 участников с диагнозом депрессия). Продемонстрированные показатели обнаружения депрессии по данным ЭЭГ (табл. 4) не позволяют с уверенностью заявить о возможной генерализации результатов для больших наборов данных, что подтверждается аналогичными работами [55].

Хотя сам метод трансферного обучения, реализованный на полученной паре базовых сетей на базе 1D CNN, выглядит перспективным, специфичность ЭЭГ-сигналов и решаемых на их основе задач требует масштабной адаптации алгоритмов и техник контрастной оптимизации для эффективного обучения целевой задаче. Например, важным условием успешности контрастного обучения является корректная процедура аугментации, определяющая индуктивное смещение в поиске повторяющихся паттернов весов сети. Нахождение наиболее эффективных преобразований характеристики отдельных наблюдений для сигналов ЭЭГ представляет собой отдельную сложную задачу и сильно зависит от экспертного представления о природе признаков депрессии. Это особенно актуально для наборов данных с большим количеством испытуемых, значительно различающихся между собой, одной из задач, для которой заявлено эффективное использование трансферного обучения [52].

Активно исследуются в последние несколько лет новые, потенциально более подходящие для контрастного обучения архитектуры базовых сетей и алгоритмов обучения [41, 42]. Так, показана эффективность трансферного обучения единой модели классификации депрессии для разнородных мультимодальных данных, в том числе значительно отличающихся по своей природе, например, содержащих аудио и текст [55]. Хотя в общем случае (например, для графических изображений) никаких специальных модификаций сети не требуется, существует вероятность того, что для эффективного выделения всех полезных паттернов из сигнала ЭЭГ в рамках контрастного обучения необходимы специфические архитектуры сетей, отличные от стандартных сверточных и полносвязных слоёв или комбинации нескольких сетей меньшего размера [55, 56]. Одним из модифицированных вариантов контрастного обучения является применение меток классов для конструирования позитивных/негативных пар и сохранение контрастной целевой функции в ходе трансфера в качестве своеобразной регуляризации [57].

## **Заключение**

Полученные результаты проведенного экспериментального сравнения точности классификации нескольких алгоритмов трансферного обучения выделяют решающую роль представительности набора данных для обучения базовой сети. Полнота реальных наблюдений повышает эффективность аугментации, обеспечивая увеличение числа «полезных» признаков в латентном пространстве сети, и создает лучшие условия для трансферного обучения в целевой задаче [58]. Полученные результаты точности классификации 64–66% в целом коррелируют с результатами определения эмоционального состояния пользователей по данным ЭЭГ. Для классификации эмоционального состояния с учетом разбиения обучающих и тестовых данных по отдельным участникам (Inter-Subject) точность составляет 45–68%, что существенно меньше показателя 74–95% для классификации на данных одного и того же участника (Intra-Subject) [59]. Продемонстрированные результаты могут свидетельствовать об уникальности индивидуальных наборов пространственно-спектральных характеристик ЭЭГ, отражающих гетерогенную природу депрессии [60].

## **Список литературы**

1. *Karpov O. E., Храмов A. E.* Информационные технологии, вычислительные системы и искусственный интеллект в медицине. М.: ДПК Пресс, 2022. 479 с.
2. *Karpov O. E., Pitsik E. N., Kurkin S. A., Maksimenko V. A., Gusev A. V., Shusharina N. N., Hramov A. E.* Analysis of publication activity and research trends in the field of AI medical applications: Network approach // International Journal of Environmental Research and Public Health. 2023. Vol. 20, iss. 7. C. 5335. DOI: 10.3390/ijerph20075335.
3. *Yuan J., Ran X., Liu K., Yao C., Yao Y., Wu H., Liu Q.* Machine learning applications on neuroimaging for diagnosis and prognosis of epilepsy: A review // Journal of Neuroscience Methods. 2022. Vol. 15, iss. 368. P. 109441. DOI: 10.1016/j.jneumeth.2021.109441.
4. *Karpov O. E., Grubov V. V., Maksimenko V. A., Kurkin S. A., Smirnov N. M., Utyashev N. P., Andrikov D. A., Shusharina N. N., Hramov A. E.* Extreme value theory inspires explainable machine learning approach for seizure detection // Scientific Reports. 2022. Vol. 12. P. 11474. DOI: 10.1038/s41598-022-15675-9.
5. *Karpov O. E., Afinogenov S., Grubov V. V., Maksimenko V., Korchagin S., Utyashev N., Hramov A. E.* Detecting epileptic seizures using machine learning and interpretable features of human EEG // The European Physical Journal Special Topics. 2023. Vol. 232, no. 5. P. 673–682. DOI: 10.1140/epjs/s11734-022-00714-3.
6. *Erguzel T. T., Sayar G. H., Tarhan N.* Artificial intelligence approach to classify unipolar and bipolar depressive disorders // Neural Computing and Applications. 2016. Vol. 27, iss. 6. P. 1607–1616. DOI: 10.1007/s00521-015-1959-z.
7. *Andreev A. V., Kurkin S. A., Stoyanov D., Badarin A. A., Paunova R., Hramov A. E.* Toward interpretability of machine learning methods for the classification of patients with major depressive disorder based on functional network measures // Chaos. 2023. Vol. 33, iss. 6. P. 063140. DOI: 10.1063/5.0155567.
8. *Stoyanov D., Khorev V., Paunova R., Kandilarova S., Simeonova D., Badarin A., Hramov A., Kurkin S.* Resting-state functional connectivity impairment in patients with major depressive episode // International Journal of Environmental Research and Public Health. 2022. Vol. 19, iss. 21. P. 14045. DOI: 10.3390/ijerph192114045.
9. *Chaddad A., Li J., Lu Q., Li Y., Okuwobi I. P., Tanougast C., Desrosiers C., Niazi T.* Can autism Be diagnosed with artificial intelligence? A narrative review // Diagnostics. 2021. Vol. 11, iss. 11. P. 2032. DOI: 10.3390/diagnostics1112032.
10. *Song D. Y., Kim S. Y., Bong G., Kim J. M., Yoo H. J.* The use of artificial intelligence in screening

- and diagnosis of autism spectrum disorder: a literature review // Journal of the Korean Academy of Child and Adolescent Psychiatry. 2019. Vol. 30. iss. 4. P. 145-152. DOI: 10.5765/jkacap.190027.
- 11. Sysoeva O., Maximenko V., Kuc A., Voinova V., Martynova O., Hramov A. Abnormal spectral and scale-free properties of resting-state EEG in girls with Rett syndrome // Scientific Reports. 2023. Vlo. 13. P. 12932. DOI: 10.1038/s41598-023-39398-7.
  - 12. Zhang Z., Li G., Xu Y., Tang X. Application of artificial intelligence in the MRI classification task of human brain neurological and psychiatric diseases: A scoping review // Diagnostics. 2021. Vol. 11, iss. 8. P. 1402. DOI: 10.3390/diagnostics11081402.
  - 13. Pitsik E. N., Maximenko V. A., Kurkin S. A., Sergeev A. P., Stoyanov D., Paunova R., Kandilarova S., Simeonova D., Hramov A. E. The topology of fMRI-based networks defines the performance of a graph neural network for the classification of patients with major depressive disorder // Chaos, Solitons & Fractals. 2023. Vol. 167. P. 113041. DOI: 10.1016/j.chaos.2022.113041.
  - 14. Ramzan F., Khan M. U., Rehmat A., Iqbal S., Saba T., Rehman A., Mehmood Z. A deep learning approach for automated diagnosis and multi-class classification of Alzheimer's disease stages using resting-state fMRI and residual neural networks // Journal of Medical Systems. 2020. Vol. 44. P. 1-6. DOI: 10.1007/s10916-019-1475-2.
  - 15. Alorf A., Khan M. U. Multi-label classification of Alzheimer's disease stages from resting-state fMRI-based correlation connectivity data and deep learning // Computers in Biology and Medicine. 2022. Vol. 151, iss. 6. P. 106240. DOI: 10.1016/j.combiomed.2022.106240.
  - 16. Subha D. P., Joseph P. K., Acharya U. R., Lim C. M. EEG signal analysis: a survey // Journal of Medical Systems. 2010. Vol. 34, iss. 2. P. 195-212. DOI: 10.1007/s10916-008-9231-z.
  - 17. Lotte F., Congedo M., Lécuyer A., Fabrice L., Arnaldi B. A review of classification algorithms for EEG-based brain-computer interfaces // Journal of Neural Engineering. 2007. Vol. 4, iss. 2. P. R1. DOI: 10.1088/1741-2560/4/2/R01.
  - 18. Kang H., Nam Y., Choi S. Composite common spatial pattern for subject-to-subject transfer // IEEE Signal Processing Letters. 2009. Vol. 16, iss. 8. P. 683-686. DOI: 10.1109/LSP.2009.2022557.
  - 19. Wan Z., Yang R., Huang M., Zeng N., Liu X. A review on transfer learning in EEG signal analysis // Neurocomputing. 2021. Vol. 421. P. 1-14. DOI: 10.1016/j.neucom.2020.09.017.
  - 20. Wu D., Xu Y., Lu B.-L. Transfer Learning for EEG-Based Brain-Computer Interfaces: A Review of Progress Made Since 2016 // IEEE Trans. on Cognitive and Developmental Systems. 2022. Vol. 14, iss. 1. P. 4-19. DOI: 10.1109/TCDS.2020.3007453.
  - 21. Kuc A., Korchagin S., Maksimenko V. A., Shusharina N., Hramov A. E. Combining statistical analysis and machine learning for EEG scalp topograms classification // Frontiers in Systems Neuroscience. 2021. Vol. 15. DOI: 10.3389/fnsys.2021.716897.
  - 22. Luo Y., Lu B.-L. EEG data augmentation for emotion recognition using a conditional Wasserstein GAN // 2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC). IEEE, 2018. P. 2535-2538. DOI: 10.1109/EMBC.2018.8512865.
  - 23. Weiss K., Khoshgoftaar T. M., Wang D. D. A survey of transfer learning // Journal of Big data. 2016. Vol. 3, iss. 1. P. 1-40. DOI: 10.1186/s40537-016-0043-6.
  - 24. Azab A. M., Ahmadi H., Mihaylova L., Arvaneh M. Dynamic time warping-based transfer learning for improving common spatial patterns in brain-computer interface // Journal of Neural Engineering. 2020. Vol. 17, iss. 1. P. 016061. DOI: 10.1088/1741-2552/ab64a0.
  - 25. Raghu S., Natarajan S., Temel Y., Rao S. V., Kubben P. EEG based multi-class seizure type classification using convolutional neural network and transfer learning // Neural Networks. 2020. Vol. 124. P. 202-212. DOI: 10.1016/j.neunet.2020.01.017.
  - 26. Nejedly P., Cimbalnik J., Klimeš P., Plesinger F., Halamek J., Křemen V., Viscor I., Brinkmann B. H., Pail M., Brazdil M., Worrell G., Jurak P. Intracerebral EEG artifact identification using convolu-

- tional neural networks // Neuroinformatics. 2019. Vol. 17, iss. 3. P. 225-234. DOI: 10.1007/s12021-018-9397-6.
27. *Hramov A. E., Maksimenko V. A., Pisarchik A. N.* Physical principles of brain-computer interfaces and their applications for rehabilitation, robotics and control of human brain states // Physics Reports. 2021. Vol. 918. P. 1-133. DOI: 10.1016/j.physrep.2021.03.002.
  28. *Shen X., Liu X., Hu X., Zhang D., Song S.* Contrastive learning of subject-invariant EEG representations for cross-subject emotion recognition // IEEE Transactions on Affective Computing. 2023. Vol. 14, no. 3. P. 2496-2511. DOI: 10.1109/TAFFC.2022.3164516.
  29. *Chen T., Kornblith S., Norouzi M., Hinton G.* A simple framework for contrastive learning of visual representations // International conference on machine learning (PMLR). 2020. P. 1597-1607. arXiv:2002.05709. DOI: 10.48550/arXiv.2002.05709.
  30. *Jaiswal A., Babu A. R., Zadeh M. Z., Banerjee D., Makedon F.* A survey on contrastive self-supervised learning // Technologies. 2020. Vol. 9, iss. 1. P. 2. DOI: 10.3390/technologies9010002.
  31. *Żygierewicz J., Janik R. A., Podolak I. T., Drozd A., Malinowska U., Poziomska M., Wojciechowski J., Ogniewski P., Niedbalski P., Terczynska I., Rogala J.* Decoding working memory-related information from repeated psychophysiological EEG experiments using convolutional and contrastive neural networks // Journal of Neural Engineering. 2022. Vol. 19, iss. 4. P. 046053. DOI: 10.1088/1741-2552/ac8b38.
  32. *Hadsell R., Chopra S., LeCun Y.* Dimensionality reduction by learning an invariant mapping // 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol. 2 (CVPR'06). IEEE, 2006. P. 1735-1742. DOI: 10.1109/CVPR.2006.100.
  33. *He K., Fan H., Wu Y., Xie S., Girshick R.* Momentum contrast for unsupervised visual representation learning // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020. P. 9729-9738. DOI: 10.1109/CVPR42600.2020.00975.
  34. *Dwibedi D., Aytar Y., Tompson J., Sermanet P., Zisserman A.* With a little help from my friends: Nearest-neighbor contrastive learning of visual representations // Proceedings of the IEEE/CVF International Conference on Computer Vision, Montreal, QC, Canada, 2021. P. 9588-9597. DOI: 10.1109/ICCV48922.2021.00945.
  35. *Zbontar J., Jing L., Misra I., LeCun Y., Deny S.* Barlow twins: Self-supervised learning via redundancy reduction // International Conference on Machine Learning (PMLR), 2021. P. 12310-12320. arXiv:2103.03230. DOI: 10.48550/arXiv.2103.03230.
  36. *Caron M., Touvron H., Misra I., Jégou H., Mairal J., Bojanowski P., Joulin A.* Emerging properties in self-supervised vision transformers // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021. C. 9650-9660. arXiv:2104.14294. DOI: 10.48550/arXiv.2104.14294
  37. Self-supervised Contrastive Learning for Image Classification with Keras [Электронный ресурс]. Дата обращения: 16.01.2024. <https://github.com/beresandras/contrastive-classification-keras>.
  38. *Alexander L. M., Escalera J., Ai L., Andreotti C., Febre K., Mangone A., Vega-Potler N., Langer N., Alexander A., Kovacs M., Litke S., O'Hagan B., Andersen J., Bronstein B., Bui A., Bushey M., Butler H., Castagna V., Camacho N., Chan E., Citera D., Clucas J., Cohen S., Dufek S., Eaves M., Fradera B., Gardner J., Grant-Villegas N., Green G., Gregory C., Hart E., Harris S., Horton M., Kahn D., Kabotyanski K., Karmel B., Kelly S. P., Kleinman K., Koo B., Kramer E., Lennon E., Lord C., Mantello G., Margolis A., Merikangas K. R., Milham J., Minniti G., Neuhaus R., Levine A., Osman Y., Parra L. C., Pugh K. R., Racanello A., Restrepo A., Saltzman T., Septimus B., Tobe R., Waltz R., Williams A., Yeo A., Castellanos F. X., Klein A., Paus T., Leventhal B. L., Craddock R. C., Koplewicz H. S., Milham M. P.* HBN EO/EC task. OpenNeuro Accession Number ds004186. DOI: doi:10.18112/openneuro.ds004186.v2.0.0.
  39. *Gramfort A., Luessi M., Larson E., Engemann D. A., Strohmeier D., Brodbeck C., Goj R., Jas M., Brooks T., Parkkonen L., Hämäläinen M.* MEG and EEG data analysis with MNE-Python // Frontiers in Neuroscience. 2013. Vol. 7. P. 267. DOI: 10.3389/fnins.2013.00267.

40. Mumtaz W. MDD Patients and Healthy Controls EEG Data (New). Dataset. 2016. DOI: 10.6084/m9.figshare.4244171.v2
41. Cavanagh J. F. EEG: Depression rest. Dataset. 2021. DOI: 10.18112/openneuro.ds003478.v1.1.0.
42. Cai H., Gao Y., Sun S., Li N., Tian F., Xiao H., Hu B. MODMA dataset: a Multi-modal Open Dataset for Mental-disorder Analysis. arXiv:2002.09283. 2020. <http://modma.lzu.edu.cn/data/application/>.
43. van Dijk H., van Wingen G. A., Denys D., Olbrich S., van Ruth R., Arns M. The two decades brainclinics research archive for insights in neurophysiology (TDBRAIN) database // Scientific Data. 2022. Vol. 9, iss. 1. P. 1-10. DOI: 10.1038/s41597-022-01409-z.
44. Maaten L., Hinton G. Visualizing data using t-sne // Journal of Machine Learning Research. 2008. Vol. 9. P. 2579-2605.
45. Sandheep P., Vineeth S., Poulose M., Subha D. P. Performance analysis of deep learning CNN in classification of depression EEG signals // TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON), Kochi, India. IEEE, 2019. P. 1339-1344. DOI: 10.1109/TENCON.2019.8929254.
46. Lawhern V. J., Solon A. J., Waytowich N., Gordon S. M., Hung C. P., Lance B. J. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces // Journal of neural engineering. 2018. Vol. 15, iss. 5. P. 056013. DOI: 10.1088/1741-2552/aace8c.
47. LeCun Y. A., Bottou L., Orr G. B., Müller K.-R. Efficient BackProp // In: Montavon G., Orr G. B., Müller K. R. (eds) Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science, vol. 7700. Berlin, Heidelberg: Springer, 2012. P. 9-48.
48. van Dijk H., Koppenberg M., Arns M. Towards robust, reproducible, and clinically actionable EEG biomarkers: Large open access EEG Database for discovery and out-of-sample validation // Clinical EEG and Neuroscience. 2022. Vol. 54, iss. 2. DOI: 10.1177/15500594221120516.
49. Darvishi-Bayazi M.-J., Ghaemi M. S., Lesort T., Arefin Md R., Faubert J., Rish I. Amplifying pathological detection in EEG signaling pathways through cross-dataset transfer learning. arXiv:2309.10910. DOI: 10.48550/arXiv.2309.10910
50. Zeng H., Li X., Borghini G., Zhao Y., Aricò P., Di Flumeri G., Sciaraffa N., Zakaria W., Kong W., Babiloni F. An EEG-based transfer learning method for cross-subject fatigue mental state prediction // Sensors. 2021. Vol. 21, iss. 7. P. 2369. DOI: 10.3390/s21072369.
51. Zhang K., Xu G., Zheng X., Li H., Zhang S., Yu Y., Liang R. Application of transfer learning in EEG decoding based on brain-computer interfaces: A review // Sensors. 2020. Vol. 20, iss. 21. P. 1-25. DOI: 10.3390/s20216321.
52. Deep Learning Applications. Vol. 4 / M. Arif Wani, Vasile Palade (eds.). Advances in Intelligent Systems and Computing, Vol. 1434. Singapore: Springer, 2023. 384 p. DOI: 10.1007/978-981-19-6153-3
53. Seal A., Bajpai R., Agnihotri J., Yazidi A., Herrera-Viedma E., Krejcar O. DeprNet: A deep convolution neural network framework for detecting depression using EEG // IEEE Transactions on Instrumentation and Measurement. 2021. Vol. 70. P. 1-13. 2505413. DOI: 10.1109/TIM.2021.3053999.
54. Sharma G., Parashar A., Joshi A. M. DepHNN: A novel hybrid neural network for electroencephalogram (EEG)-based screening of depression // Biomedical Signal Processing and Control. 2021. Vol. 66. P. 102393. DOI: 10.1016/j.bspc.2020.102393.
55. Uran A., van Gemeren C., van Diepen R., Chavarriaga R., del R. Millán J. Applying transfer learning to deep learned models for EEG analysis. arXiv:1907.01332. DOI: 10.48550/arXiv.1907.01332.
56. Osman Berke Guney, Huseyin Ozkan Transfer Learning of an Ensemble of DNNs for SSVEP BCI Spellers without User-Specific Training. arXiv:2209.01511. DOI: 10.48550/arXiv.2209.01511.
57. Ju C., Gao D., Mane R., Tan B., Liu Y., Guan C. Federated Transfer Learning for EEG Signal Classification // 42nd Annual International Conference of the IEEE Engineering in Medicine &

- Biology Society (EMBC), Montreal, QC, Canada, 2020. P. 3040-3045. DOI: 10.1109/EMBC44109.2020.9175344.
58. *Khosla P., Teterwak P., Wang C., Sarna A., Tian Y., Isola Ph., Maschinot A., Liu C., Krishnan D.* Supervised contrastive learning // Advances in Neural Information Processing Systems. 2020. Vol. 33. P. 18661-18673. ArXiv:abs/2004.11362. <https://api.semanticscholar.org/CorpusID:216080787>.
  59. *Lv Z., Zhang J., Epota Oma E.* A novel method of emotion recognition from multi-band EEG topology maps based on ERENNet // Appl. Sci. 2022. Vol. 12. 10273. DOI: <https://doi.org/10.3390/app122010273>.
  60. *Xiao J., Provenzaa N.R., Asfouric J., Myersa J., Mathuraa R.K., Metzgera B., Adkinsona J.A., Allawalad A.B., Pirtlea V., Oswalta D., Shoftya B., Robinsona M.E., Mathewe S.J., Goodmanae W.K., Pouratianf N., Schraterg P.R., Patel A.B., Tolias A.S., Bijankia K.R., Pitkowb X., Sheth S.A.* Decoding depression severity from intracranial neural activity // Biological Psychiatry. 2023. Vol. 94, iss. 6. P. 445-453. DOI: 10.1016/j.biopsych.2023.01.020.

## References

1. Karpov OE, Khramov AE. Information technologies, computing systems and artificial intelligence in medicine. Moscow: DPK Press; 2022. 479 p.
2. Karpov OE, Pitsik EN, Kurkin SA, Maksimenko VA, Gusev AV, Shusharina NN, Hramov AE. Analysis of Publication Activity and Research Trends in the Field of AI Medical Applications: Network Approach. International Journal of Environmental Research and Public Health. 2023;20:5335. DOI: 10.3390/ijerph20075335.
3. Yuan J, Ran X, Liu K, Yao C, Yao Y, Wu H, Liu Q. Machine learning applications on neuroimaging for diagnosis and prognosis of epilepsy: A review. Journal of Neuroscience Methods. 2022;368:109441. DOI: 10.1016/j.jneumeth.2021.109441.
4. Karpov OE, Grubov VV, Maksimenko VA, Kurkin SA, Smirnov NM, Utyashev NP, Andrikov DA, Shusharina NN, Hramov AE. Extreme value theory inspires explainable machine learning approach for seizure detection. Scientific Reports. 2022;12:11474. DOI: 10.1038/s41598-022-15675-9.
5. *Karpov OE, Afinogenov S, Grubov VV, Maksimenko V, Korchagin S, Utyashev N, Hramov AE.* Detecting epileptic seizures using machine learning and interpretable features of human EEG. The European Physical Journal Special Topics. 2023;232(5):673-682. DOI: 10.1140/epjs/s11734-022-00714-3.
6. *Erguzel TT, Sayar GH, Tarhan N.* Artificial intelligence approach to classify unipolar and bipolar depressive disorders. Neural Computing and Applications. 2016;27(6):1607-1616. DOI: 10.1007/s00521-015-1959-z.
7. *Andreev AV, Kurkin SA, Stoyanov D, Badarin AA, Paunova R, Hramov AE.* Toward interpretability of machine learning methods for the classification of patients with major depressive disorder based on functional network measures. Chaos. 2023;33(6):063140. DOI: 10.1063/5.0155567.
8. *Stoyanov D, Khorev V, Paunova R, Kandilarova S, Simeonova D, Badarin A, Hramov A, Kurkin S.* Resting-state functional connectivity impairment in patients with major depressive episode. International Journal of Environmental Research and Public Health. 2022;19(21):14045. DOI: 10.3390/ijerph192114045.
9. Chaddad A, Li J, Lu Q, Li Y, Okuwobi IP, Tanougast C, Desrosiers C, Niazi T. Can autism Be diagnosed with artificial intelligence? A narrative review. Diagnostics. 2021;11(11):2032. DOI: 10.3390/diagnostics11112032.
10. Song DY, Kim SY, Bong G, Kim JM, Yoo HJ. The use of artificial intelligence in screening and diagnosis of autism spectrum disorder: a literature review. Journal of the Korean Academy of Child and Adolescent Psychiatry. 2019;30(4):145-152. DOI: 10.5765/jkacap.190027.

11. Sysoeva O, Maximenko V, Kuc A, Voinova V, Martynova O, Hramov A. Abnormal spectral and scale-free properties of resting-state EEG in girls with Rett syndrome. *Scientific Reports*. 2023;13:12932. DOI: 10.1038/s41598-023-39398-7.
12. Zhang Z, Li G, Xu Y, Tang X. Application of artificial intelligence in the MRI classification task of human brain neurological and psychiatric diseases: A scoping review. *Diagnostics*. 2021;11(8):1402. DOI: 10.3390/diagnostics11081402.
13. Pitsik EN, Maximenko VA, Kurkin SA, Sergeev AP, Stoyanov D, Paunova R, Kandilarova S, Simeonova D, Hramov AE. The topology of fMRI-based networks defines the performance of a graph neural network for the classification of patients with major depressive disorder. *Chaos, Solitons & Fractals*. 2023;167:113041. DOI: 10.1016/j.chaos.2022.113041.
14. Ramzan F, Khan MU, Rehmat A, Iqbal S, Saba T, Rehman A, Mehmood Z. A deep learning approach for automated diagnosis and multi-class classification of Alzheimer's disease stages using resting-state fMRI and residual neural networks. *Journal of medical systems*. 2020;44:1-6. DOI: 10.1007/s10916-019-1475-2.
15. Alorf A, Khan MU. Multi-label classification of Alzheimer's disease stages from resting-state fMRI-based correlation connectivity data and deep learning. *Computers in Biology and Medicine*. 2022;151(6):106240. DOI: 10.1016/j.combiomed.2022.106240.
16. Subha DP, Joseph PK, Acharya UR, Lim CM. EEG signal analysis: a survey. *Journal of medical systems*. 2010;34(2):195-212. DOI: 10.1007/s10916-008-9231-z.
17. Lotte F, Congedo M, Lécuyer A, Fabrice L, Arnaldi B. A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of Neural Engineering*. 2007;4(2):R1. DOI: 10.1088/1741-2560/4/2/R01.
18. Kang H, Nam Y, Choi S. Composite common spatial pattern for subject-to-subject transfer. *IEEE Signal Processing Letters*. 2009;16(8):683-686. DOI: 10.1109/LSP.2009.2022557.
19. Wan Z, Yang R, Huang M, Zeng N, Liu X. A review on transfer learning in EEG signal analysis. *Neurocomputing*. 2021;421:1-14. DOI: 10.1016/j.neucom.2020.09.017.
20. Wu D, Xu Y, Lu B-L. Transfer Learning for EEG-Based Brain-Computer Interfaces: A Review of Progress Made Since 2016. *IEEE Trans. on Cognitive and Developmental Systems*. 2022;14(1):4-19. DOI: 10.1109/TCDS.2020.3007453.
21. Kuc A, Korchagin S, Maksimenko VA, Shusharina N, Hramov AE. Combining Statistical Analysis and Machine Learning for EEG Scalp Topograms Classification. *Frontiers in Systems Neuroscience*. 2021;15. DOI: 10.3389/fnsys.2021.716897.
22. Luo Y, Lu B-L. EEG data augmentation for emotion recognition using a conditional Wasserstein GAN. 2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC). IEEE, 2018. P. 2535-2538. DOI: 10.1109/EMBC.2018.8512865.
23. Weiss K, Khoshgoftaar TM, Wang DD. A survey of transfer learning. *Journal of Big data*. 2016;3(1):1-40. DOI: 10.1186/s40537-016-0043-6.
24. Azab AM, Ahmadi H, Mihaylova L, Arvaneh M. Dynamic time warping-based transfer learning for improving common spatial patterns in brain-computer interface. *Journal of Neural Engineering*. 2020;17(1):016061. DOI: 10.1088/1741-2552/ab64a0.
25. Raghu S, Natarajan S, Temel Y, Rao SV, Kubben P. EEG based multi-class seizure type classification using convolutional neural network and transfer learning. *Neural Networks*. 2020;124:202-212. DOI: 10.1016/j.neunet.2020.01.017.
26. Nejedly P, Cimbalník J, Klimeš P, Plesinger F, Halamek J, Křemen V, Viscor I, Brinkmann BH, Pail M, Brazdil M, Worrell G, Jurak P. Intracerebral EEG artifact identification using convolutional neural networks. *Neuroinformatics*. 2019;17(3):225-234. DOI: 10.1007/s12021-018-9397-6.
27. Hramov AE, Maksimenko VA, Pisarchik AN. Physical principles of brain-computer interfaces and their applications for rehabilitation, robotics and control of human brain states. *Physics Reports*. 2021;918:1-133. DOI: 10.1016/j.physrep.2021.03.002.

28. Shen X, Liu X, Hu X, Zhang D, Song S. Contrastive learning of subject-invariant EEG representations for cross-subject emotion recognition. *IEEE Transactions on Affective Computing*. 2023;14(3):2496-2511. DOI: 10.1109/TAFFC.2022.3164516.
29. Chen T, Kornblith S, Norouzi M, Hinton G. A simple framework for contrastive learning of visual representations. International conference on machine learning (PMLR). arXiv:2002.05709. 2020. P. 1597-1607. DOI: 10.48550/arXiv.2002.05709.
30. Jaiswal A, Babu AR, Zadeh MZ, Banerjee D, Makedon F. A survey on contrastive self-supervised learning. *Technologies*. 2020;9(1):2. DOI: 10.3390/technologies9010002.
31. Źygierek J, Janik RA, Podolak IT, Drozd A, Malinowska U, Poziomska M, Wojciechowski J, Ogniewski P, Niedbalski P, Terczynska I, Rogala J. Decoding working memory-related information from repeated psychophysiological EEG experiments using convolutional and contrastive neural networks. *Journal of Neural Engineering*. 2022;19(4):046053. DOI: 10.1088/1741-2552/ac8b38.
32. Hadsell R, Chopra S, LeCun Y. Dimensionality reduction by learning an invariant mapping. 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol. 2 (CVPR'06). IEEE, 2006. P. 1735-1742. DOI: 10.1109/CVPR.2006.100.
33. He K, Fan H, Wu Y, Xie S, Girshick R. Momentum contrast for unsupervised visual representation learning. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020. P. 9729-9738. DOI: 10.1109/CVPR42600.2020.00975.
34. Dwibedi D, Aytar Y, Tompson J, Sermanet P, Zisserman A. With a little help from my friends: Nearest-neighbor contrastive learning of visual representations. Proceedings of the IEEE/CVF International Conference on Computer Vision, Montreal, QC, Canada, 2021. P. 9588-9597. DOI: 10.1109/ICCV48922.2021.00945.
35. Zbontar J, Jing L, Misra I, LeCun Y, Deny S. Barlow twins: Self-supervised learning via redundancy reduction. International Conference on Machine Learning (PMLR). arXiv:2103.03230. 2021. P. 12310-12320. DOI: 10.48550/arXiv.2103.03230.
36. Caron M, Touvron H, Misra I, Jégou H, Mairal J, Bojanowski P, Joulin A. Emerging properties in self-supervised vision transformers. Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021. P. 9650-9660.
37. Self-supervised Contrastive Learning for Image Classification with Keras [Electronic resource]. <https://github.com/beresandras/contrastive-classification-keras> (Date of reference: 16.01.2024).
38. Alexander LM, Escalera J, Ai L, Andreotti C, Febre K, Mangone A, Vega-Potler N, Langer N, Alexander A, Kovacs M, Litke S, O'Hagan B, Andersen J, Bronstein B, Bui A, Bushey M, Butler H, Castagna V, Camacho N, Chan E, Citera D, Clucas J, Cohen S, Dufek S, Eaves M, Fradera B, Gardner J, Grant-Villegas N, Green G, Gregory C, Hart E, Harris S, Horton M, Kahn D, Kabotyanski K, Karmel B, Kelly SP, Kleinman K, Koo B, Kramer E, Lennon E, Lord C, Mantello G, Margolis A, Merikangas KR, Milham J, Minniti G, Neuhaus R, Levine A, Osman Y, Parra LC, Pugh KR, Racanello A, Restrepo A, Saltzman T, Septimus B, Tobe R, Waltz R, Williams A, Yeo A, Castellanos FX, Klein A, Paus T, Leventhal BL, Craddock RC, Koplewicz HS, Milham MP. HBN EO/EC task. OpenNeuro Accession Number ds004186. DOI: doi:10.18112/openneuro.ds004186.v2.0.0.
39. Gramfort A, Luessi M, Larson E, Engemann DA, Strohmeier D, Brodbeck C, Goj R, Jas M, Brooks T, Parkkonen L, Härmäläinen M. MEG and EEG data analysis with MNE-Python. *Frontiers in Neuroscience*. 2013;7:267. DOI: 10.3389/fnins.2013.00267.
40. Mumtaz W. MDD Patients and Healthy Controls EEG Data (New). Dataset. 2016. DOI: 10.6084/m9.figshare.4244171.v2
41. Cavanagh JF. EEG: Depression rest. Dataset. 2021. DOI: 10.18112/openneuro.ds003478.v1.1.0.
42. Cai H, Gao Y, Sun S, Li N, Tian F, Xiao H, Hu B. MODMA dataset: a Multi-modal Open Dataset for Mental-disorder Analysis. arXiv:2002.09283. 2020. <http://modma.lzu.edu.cn/data/application/>.
43. van Dijk H, van Wingen GA, Denys D, Olbrich S, van Ruth R, Arns M. The two decades

- brainclinics research archive for insights in neurophysiology (TDBRAIN) database. *Scientific Data.* 2022;9(1):1-10. DOI: 10.1038/s41597-022-01409-z.
- 44. Maaten L, Hinton G. Visualizing data using t-sne. *Journal of Machine Learning Research.* 2008;9:2579-2605.
  - 45. Sandheep P, Vineeth S, Poulose M, Subha DP. Performance analysis of deep learning CNN in classification of depression EEG signals. *TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON), Kochi, India. IEEE,* 2019. P. 1339-1344. DOI: 10.1109/TENCON.2019.8929254.
  - 46. Lawhern VJ, Solon AJ, Waytowich N, Gordon SM, Hung CP, Lance BJ. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of neural engineering.* 2018;15(5):056013. DOI: 10.1088/1741-2552/aace8c.
  - 47. LeCun YA, Bottou L, Orr GB, Müller K-R. In: Efficient backprop Montavon G., Orr G. B., Müller K. R. (eds) *Neural Networks: Tricks of the Trade.* Lecture Notes in Computer Science, vol. 7700. Berlin, Heidelberg: Springer; 2012. P. 9-48.
  - 48. van Dijk H, Koppenberg M, Arns M. Towards robust, reproducible, and clinically actionable EEG biomarkers: Large open access EEG Database for discovery and out-of-sample validation. *Clinical EEG and Neuroscience.* 2023;54(2):103-105. DOI: <http://dx.doi.org/10.1177/15500594221120516>
  - 49. Darvishi-Bayazi M-J, Ghaemi MS, Lesort T, Md Arefin R, Faubert J, Rish I. Amplifying pathological detection in EEG signaling pathways through cross-dataset transfer learning. *arXiv:* 2309.10910. DOI: 10.48550/arXiv.2309.10910
  - 50. Zeng H, Li X, Borghini G, Zhao Y, Aricò P, Di Flumeri G, Sciaraffa N, Zakaria W, Kong W, Babiloni F. An EEG-based transfer learning method for cross-subject fatigue mental state prediction. *Sensors (Basel).* 2021;21(7):2369. DOI: 10.3390/s21072369.
  - 51. Zhang K, Xu G, Zheng X, Li H, Zhang S, Yu Y, Liang R. Application of transfer learning in EEG decoding based on brain-computer interfaces: A review. *Sensors.* 2020;20(21):1-25. DOI: 10.3390/s20216321.
  - 52. Deep Learning Applications. Vol. 4 / M. Arif Wani, Vasile Palade (eds) *Advances in Intelligent Systems and Computing,* Vol. 1434. Singapore: Springer; 2023. 384 p. DOI: 10.1007/978-981-19-6153-3.
  - 53. Seal A, Bajpai R, Agnihotri J, Yazidi A, Herrera-Viedma E, Krejcar O. DeprNet: A deep convolution neural network framework for detecting depression using EEG. *IEEE Transactions on Instrumentation and Measurement.* 2021;70:2505413. DOI: 10.1109/TIM.2021.3053999.
  - 54. Sharma G, Parashar A, Joshi AM. DepHNN: A novel hybrid neural network for electroencephalogram (EEG)-based screening of depression. *Biomedical Signal Processing and Control.* 2021;66:102393. DOI: 10.1016/j.bspc.2020.102393.
  - 55. Uran A, van Gemeren C, van Diepen R, Chavarriaga R, del R. Millán J. Applying transfer learning to deep learned models for EEG analysis. *arXiv:*1907.01332. DOI: 10.48550/arXiv.1907.01332
  - 56. Osman Berke Guney, Huseyin Ozkan Transfer Learning of an Ensemble of DNNs for SSVEP BCI Spellers without User-Specific Training. *arXiv:*2209.01511. DOI: 10.48550/arXiv.2209.01511.
  - 57. Ju C, Gao D, Mane R, Tan B, Liu Y, Guan C. Federated Transfer Learning for EEG Signal Classification. *42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Montreal, QC, Canada,* 2020. P. 3040-3045. DOI: 10.1109/EMBC44109.2020.9175344.
  - 58. Khosla P, Teterwak P, Wang C, Sarna A, Tian Y, Isola Ph, Maschinot A, Liu C, Krishnan D. Supervised contrastive learning. *Advances in Neural Information Processing Systems.* ArXiv: abs/2004.11362. 2020;33:18661-18673. <https://api.semanticscholar.org/CorpusID:216080787>.
  - 59. Lv Z, Zhang J, Epota Oma E. A novel method of emotion recognition from multi-band EEG

- topology maps based on ERENNet. *Appl. Sci.* 2022;12:10273. DOI: 10.3390/app 122010273.
60. Xiao J, Provenzaa NR, Asfouric J, Myersa J, Mathuraa RK, Metzgera B, Adkinsona JA, Allawalad AB, Pirtlea V, Oswalta D, Shoftya B, Robinsona ME, Mathewe SJ, Goodmana WK, Pouratianf N, Schraterg PR, Patel AB, Tolias AS, Bijankia KR, Pitkowb X, Sheth SA. Decoding depression severity from intracranial neural activity. *Biological Psychiatry*. 2023;94(6):445-453. DOI: 10.1016/j.biopsych.2023.01.020.



*Шушарина Наталья Николаевна* — заведующая кафедрой управления исследованиями и разработками и руководитель научной группы технологий человек-машинного взаимодействия Балтийского федерального университета имени Иммануила Канта. Кандидат педагогических наук (2013, Российский государственный педагогический университет имени А. И. Герцена). С 2014 года получает гранты и ведет исследования в области нейротехнологий и машинного обучения. Специализируется в области физики и информатики, на разработке автономных портативных телеметрических модульных устройств на основе регистрации комплекса физиологических параметров для диагностики, контроля и коррекции психофизиологических состояний нервной системы человека с использованием технологий нейробиоуправления, интерфейсов «мозг–компьютер» и искусственных нейронных сетей. Область научных интересов: создание и применение методов машинного обучения для решения задач, связанных с повышением эффективности взаимодействия человека и электронных устройств в системах «человек–машина–человек», составляющих основу современных технологий. Автор более 50 статей, опубликованных в рецензируемых научных журналах, имеет более 20 патентов.

Россия, 236041 Калининград, ул. А. Невского, 14  
Балтийский федеральный университет имени Иммануила Канта  
E-mail: nshusharina@kantiana.ru  
ORCID: 0000-0002-8848-6134  
AuthorID (eLibrary.Ru): 687638