

Применение машинного обучения к данным нейроанатомии и физиологии в области диагностики СДВГ

Сологуб П.С.

*Санкт-Петербургский государственный университет (ФГБОУ ВО СПбГУ),
г. Санкт-Петербург, Российская Федерация*

ORCID: <https://orcid.org/0009-0004-1928-2690>, e-mail: polinesku@gmail.com

Синдром дефицита внимания и гиперактивности (СДВГ) — широко распространенное расстройство развития, характеризующееся невнимательностью, импульсивностью и гиперактивностью. В то время как традиционные методы диагностики основаны на клинических интервью, тестах и поведенческих наблюдениях, методы машинного обучения (МО) дают возможность упростить процесс диагностики СДВГ и сделать его более точным. В данном обзоре предпринята попытка изучить опубликованную за последние несколько лет литературу, описывающую результаты применения алгоритмов машинного обучения к физиологическим и нейроанатомическим данным: снимкам и записям магнитно-резонансной томографии (МРТ), функциональной МРТ (фМРТ), инфракрасной спектроскопии (fNIRS), электроэнцефалографии (ЭЭГ), магнитоэнцефалографии (МЭГ), электрокардиограммы (ЭКГ), движений глаз и физической активности, а также параметров зрачков для выявления диагностических биомаркеров СДВГ. Модели глубокого обучения и алгоритм опорных векторов (SVM) демонстрируют наиболее перспективные результаты для выявления СДВГ, как у детей, так и у взрослых. Однако, несмотря на то, что с помощью методов машинного обучения исследователям удается достичь высокого уровня специфичности и чувствительности при решении задачи диагностики СДВГ, их использование в клинической практике требует предварительной работы для проверки результатов на больших выборках.

Ключевые слова: синдром дефицита внимания с гиперактивностью (СДВГ), биомаркер, машинное обучение, нейрофизиологические данные, магнито-резонансная томография, электрокардиограмма, реакция зрачка, магнитоэнцефалография, электроэнцефалограмма.

Для цитаты: *Сологуб П.С.* Применение машинного обучения к данным нейроанатомии и физиологии в области диагностики СДВГ [Электронный ресурс] // Современная зарубежная психология. 2024. Том 13. №2. С. 84—91. DOI: <https://doi.org/10.17759/jmfp.2024130208>

Application of Machine Learning to Physiological and Neuroanatomical Data in the Field of ADHD Diagnosis

Polina S. Sologub

Saint Petersburg State University, Saint Petersburg, Russia

ORCID: <https://orcid.org/0009-0004-1928-2690>, e-mail: Polinesku@gmail.com

Attention Deficit/Hyperactivity Disorder (ADHD) is a common neurodevelopmental disorder characterized by inattention, hyperactivity, and impulsivity. While traditional diagnostic methods rely on clinical interviews, tests and behavioral observations, machine learning methods provide an opportunity to simplify the ADHD diagnostic process and make it more accurate. This review tries to explore the application of machine learning (ML) algorithms to physiological and neuroanatomical data: magnetic resonance imaging (MRI), functional MRI (fMRI), near-infrared spectroscopy (fNIRS), electroencephalography (EEG), magnetoencephalography (MEG), electrocardiogram (ECG), pupil parameters, eye tracking and activity in the field of exploring biomarkers for ADHD diagnosis. Deep learning models and support vector machines (SVM) are considered the most promising approaches for identifying ADHD in both children and adults. However, despite the fact that with the help of machine learning methods researchers are able to achieve high levels of specificity and sensitivity when solving problems of ADHD assessment, their use in clinical practice requires preliminary work to verify the results on large samples, as well as addressing data security and ethical issues.

Keywords: Attention deficit hyperactivity disorder (ADHD), Biomarker, Machine Learning, Neurophysiological data, Pupillary response, Electroencephalogram, Magnetic Resonance Imaging, Heart Activity.

For citation: Sologub P.S. Application of Machine Learning to Physiological and Neuroanatomical Data in the Field of ADHD Diagnosis. *Sovremennaya zarubezhnaya psikhologiya = Journal of Modern Foreign Psychology*, 2024. Vol. 13, no. 2, pp. 84—91. DOI: <https://doi.org/10.17759/jmfp.2024130208> (In Russ.).

Введение

Синдром дефицита внимания и гиперактивности (СДВГ) — одно из самых распространенных расстройств детского возраста, характеризующееся дефицитом внимания, импульсивностью и гиперактивностью. Согласно опубликованному в апреле 2023 года метаанализу, превалентность СДВГ составляет 7,6% для детей до 12 лет, и 5,6% для подростков в возрасте с 12 до 18 лет [30].

В настоящее время не существует объективных тестов для диагностики СДВГ, так что основным подходом является клиническая оценка, основанная на критериях, определенных в диагностических руководствах — МКБ или DSM. Этот подход включает в себя взаимодействие с пациентом, сбор информации от родителей и учителей, а также психологическое тестирование. Однако он зависит от опыта и квалификации специалиста и требует значительных временных и человеческих ресурсов. Отсюда возникают такие проблемы, как гипер- и гиподиагностика, а также длительное ожидание постановки диагноза, что может ухудшить прогноз для ребенка из-за отсрочки интервенций.

Раннее выявление и коррекция симптомов СДВГ имеет важное значение, поскольку напрямую влияет на возможности социальной адаптации и повышение качества жизни человека. В свете значительной гетерогенности синдрома и неспецифичности симптомов диагностика СДВГ представляет собой нетривиальную задачу. За последнее десятилетие для ее решения стали активно использовать развивающиеся технологии искусственного интеллекта, включая машинное обучение (МО). Хотя эти методы пока не применяются в клинической практике, их эффективность в диагностике СДВГ на основе биомаркеров как измеряемых биологических характеристик, служащих индикаторами состояния организма или его функций, была успешно продемонстрирована в лабораторных условиях.

Целью данного обзора является краткое исследование недавно опубликованной литературы, касающейся применения машинного обучения для поиска биомаркеров СДВГ, в первую очередь — на основе нейрофизиологических и нейроанатомических данных, данных о сердечной и двигательной активности, реакции зрачка.

Применение машинного обучения в диагностике СДВГ

Исследования в области искусственного интеллекта оказывают значительное влияние на область диагностики нарушений детского развития: появляются новые методы обработки наборов больших данных (датасетов), создаются диагностические модели,

направленные на классификацию участников по критерию наличия или отсутствия СДВГ.

Для решения задачи классификации, т. е. отнесения каждого участника к экспериментальной или контрольной группе, используются методы обучения с учителем: модели обучаются на наборах данных, где статус СДВГ заранее известен, что позволяет обнаруживать характерные признаки, ассоциированные с диагнозом.

Для оценки прогностической эффективности моделей датасет может разделяться на обучающий и тестовый наборы данных (последний необходим для оценки результата) [16]. Для небольших датасетов часто применяются методы кросс-валидации, когда весь набор данных разделяется на k частей, каждая из которых поочередно служит в качестве тестового набора [21; 23].

Для оценки точности классификации моделей машинного обучения их результаты сопоставляются с диагнозом СДВГ, поставленным традиционными методами, такими как клинические интервью и стандартные диагностические тесты. В качестве метрики эффективности моделей используют точность (accuracy), чувствительность (sensitivity) и специфичность (specificity).

Физиологические и нейроанатомические предикторы СДВГ, используемые в машинном обучении

Работы, связанные с поисками диагностических маркеров и критериев, позволяющих упростить диагностику синдрома или предсказать постановку диагноза в более позднем возрасте, отличаются не только в отношении применяемых алгоритмов или классификаторов, но и типов данных, которые берутся в качестве исходных. Так, из электроэнцефалограммы (ЭЭГ) берутся частотные и временные характеристики: абсолютные и относительные значения амплитуд, латентности, спектральная мощность ритмов, частота пиковых интервалов (расстояние от пика до пика), измерения энтропии как показателя нерегулярности сигнала, результаты вейвлет-преобразования, позволяющего перевести полученный сигнал из временного вида в частотно-временной [1], а также данные вызванных потенциалов (ERP) — электрофизиологической активности мозга, возникающей в ответ на предъявление стимулов и во время решения заданий на внимание, память, и др. Результаты магнитно-резонансной томографии (МРТ) описывают объем, толщину коры головного мозга и других структур. Периферические данные могут включать в себя данные пупиллометрии и движений глаз (как в состоянии покоя, так и при выполнении заданий), анализ движений конечностей и их

координации, кардиограмму и данные об активности симпатической и парасимпатической ветвей вегетативной нервной системы.

Данные нейровизуализации

Существует несколько основных методов визуализации мозга: магнитно-резонансная томография (МРТ) позволяет подробно изучить отдельные структуры в мозге, а также связи между ними; функциональная МРТ (фМРТ) предназначена для изучения гемодинамики и помогает определять, какие области мозга активны во время решения определенных задач или в состоянии покоя. Инфракрасная спектроскопия (fNIRS), обладая высоким временным разрешением, позволяет через отслеживание изменений в оксигенации изучать динамику работы мозга в режиме реального времени, магнитоэнцефалография (МЭГ) [14] помогает визуализировать магнитные поля, а электроэнцефалография (ЭЭГ) обеспечивает регистрацию электрической активности мозга с высоким временным разрешением.

Для СДВГ характерны изменения как в осцилляторной активности мозга, так и структурные и функциональные изменения, которые можно фиксировать и изучать с помощью методов нейровизуализации.

Несмотря на сложность сбора МРТ- и фМРТ-данных, многие исследователи берут их за основу при поиске предикторов СДВГ: отчасти это связано с наличием в открытом доступе больших наборов записей (например, ABIDE или ADHD-200). В исследовании Пенг [19] авторам удалось достичь 90,18% точности в классификации детей с СДВГ с помощью таких предикторов, как индекс складчатости (извилистости) и объем теменной и височной долей коры головного мозга и островка. В статье Джонстон [5] на основе данных об объеме белого вещества ствола головного мозга высокая точность классификации (93%) была показана в результате применения метода опорных векторов (SVM). Объем серого вещества головного мозга и других структур (например хвостатого ядра) использовались в качестве исходных данных для классификации в исследованиях Лим [17] и Игуал [4], которые с помощью метода гауссовских процессов и SVM продемонстрировали возможности использования отдельных морфологических признаков в качестве биомаркеров СДВГ.

Некоторым исследованиям, использующим сразу несколько линейных моделей машинного обучения применительно к данным нейровизуализации, удалось приблизиться практически к 100% для показателей точности, чувствительности и специфичности: например, в статье Ортуньо-Миро [23] к данным, представляющим собой максимально репрезентативные для контрольной и экспериментальной (СДВГ) групп характеристики частотно-специфических паттернов осцилляторной активности, полученные во время решения участниками арифметической задачи посредством

метода инфракрасной спектроскопии (fNIRS), для проведения бинарной классификации применялись несколько распространенных линейных моделей МО (SVM, логистической регрессии (LR), дискриминантного анализа и наивного байесовского классификатора). При этом для достижения точности, чувствительности и специфичности, близких к 100%, понадобились всего три признака.

Уже в одном из первых исследований, где были применены методы машинного обучения для диагностики СДВГ на основе ЭЭГ данных [7; 8], точность классификации, достигнутая в результате применения метода опорных векторов (SVM), позволяющего работать с большим числом признаков, составила 90%.

В литературе описываются примеры применения различных параметров ЭЭГ в качестве исходных данных для обучения модели [27; 28; 24]. Так, морфологические характеристики ЭЭГ показали низкий уровень точности в решении задачи классификации участников эксперимента, как имеющих, так и не имеющих диагноз СДВГ: например, в исследовании Халеги [2] сравнивались временные, частотно-временные, нелинейные и морфологические характеристики ЭЭГ с помощью метода eKNN — метрического алгоритма классификации k-ближайших соседей, и морфологические характеристики показали самую низкую точность — 77,43% против 86,40% для нелинейных характеристик. Для комбинированного подхода, объединяющего морфологические и нелинейные характеристики, точность также оказалась умеренной: в результате применения исследователем Алтинкайнак [15] нескольких алгоритмов (многослойного перцептрона, наивного байесовского классификатора, SVM, логистической регрессии и случайного леса) для комбинации указанных характеристик ЭЭГ лучший результат показала нейросеть (многослойный перцептрон) с точностью 91,3%. Немного большей точности классификации (94,2%) удалось достичь Манируззаман [18] в результате применения SVM-алгоритма при объединении различных морфологических и временных характеристик ЭЭГ. В целом, нелинейные характеристики наиболее часто используются в качестве потенциальных предикторов СДВГ для разных моделей машинного обучения и показывают лучшие результаты, особенно в случае применения алгоритмов SVM.

Хотя глубокое обучение (deep learning, DL) еще не получило широкого распространения и реже используется в поиске биомаркеров СДВГ, поскольку требует больших объемов данных, тем не менее, некоторые авторы представляют многообещающие результаты: Чуг [7] объединил два метода глубокого обучения (CNN — сверточную нейросеть и LTSM — нейронную сеть с долгой краткосрочной памятью), чтобы учитывать как пространственные характеристики, так и долговременные изменения в данных ЭЭГ. Проверка работы гибридной модели на общедоступных наборах данных показала, что точность классификации составила 98,86%.

В статье Гасеми [21] записи ЭЭГ, разложенной на частотные диапазоны, использовались для сравнения предсказательной способности семи моделей, причем авторы использовали мультимодальные данные для их обучения: помимо собственно характеристик ЭЭГ, в число признаков для анализа вошли также пол и порядковый номер рождения, что увеличило предсказательную способность моделей: ошибки предсказания снизились до нуля.

Пупиллометрия

Динамика движений зрачка — еще один потенциальный биомаркер СДВГ. Исследование Чой [6] с использованием глубокого обучения показало, что дети с СДВГ демонстрируют отличия в динамике диаметра зрачка по сравнению с группой контроля. Диаметр зрачка в статье [29] значимо коррелировал с эффективностью внимания, а в исследовании Ариэль [3] была показана связь динамики зрачка с норадреналиновой системой мозга, нарушенной у людей с СДВГ. Также в некоторых исследованиях (например Нобукава [22]) отмечается связь между диаметром и асимметрией левого и правого зрачков и дефицитом внимания у взрослых участников исследования с диагнозом СДВГ. Хотя механизм, объясняющий эту связь, еще не до конца изучен, тем не менее использование методов ИИ может помочь клиницистам в выявлении потенциальных случаев синдрома. Интересный подход был предложен Дасом [12]: используя динамику диаметра зрачка как потенциального биомаркера, он в результате применения SVM добился чувствительности 77,3% и специфичности 75,3% только на основе пупиллометрии. Связанная с вниманием вергентность, отражающая слабость окуломоторного контроля у людей с СДВГ, легла в основу применения модели машинного обучения в публикации Касаль. [9].

Сердечная активность

Нарушения в работе вегетативной нервной системы (ВНС), участвующей в регуляции уровня активации, могут способствовать снижению внимания и повышению возбудимости у людей с СДВГ вследствие взаимодействия «сердце—мозг». В своем исследовании Кох [4] для решения задачи классификации людей с СДВГ с коморбидным расстройством поведения (conduct disorder) и без такового в качестве исходных данных использовал нелинейные характеристики ЭКГ, полученные в результате вейвлет-преобразования. В результате применения модели точность классификации составила 87,19%. Ту же самую задачу классификации людей с СДВГ и коморбидным расстройством поведения и без него решал и Лох [13]: минуя стадию препроцессинга ЭКГ, он использовал сырые данные для того, чтобы обучить сверточную

нейросеть (CNN), что позволило повысить точность классификации до 96,04%.

Движения

В работе Каура [25] с помощью анализа главных компонент были получены характеристики двигательной активности участников с СДВГ и группы контроля, которые затем использовались для классификации с помощью нескольких алгоритмов машинного обучения (C4.5, kNN, Random Forest, LogitBoost, SVM и Naive Bayes). SVM превзошел другие классификаторы и решил задачу отнесения участников исследования к одной из групп (с СДВГ или без СДВГ) с точностью 98,43% и чувствительностью 98,33%, что делает характеристики двигательной активности перспективным биомаркером. Движения глаз (eye tracking) также успешно использовались в качестве предиктора наличия симптомов СДВГ: в статье Мерзона [20] движения глаз участников, играющих в игру на проспективную память в виртуальной реальности, были классифицированы с помощью SVM, продемонстрировав статистически значимые различия между группами.

Возможности применения машинного обучения для диагностики подтипов СДВГ

Диагностика СДВГ с использованием методов машинного обучения может осуществляться на разных уровнях: это может быть формальное решение о принадлежности конкретного участника исследования к группе СДВГ (например, «да/нет»), подразумевающее решение задачи классификации. Однако, учитывая значительную гетерогенность синдрома, предполагающую наличие значимых различий между людьми с диагнозом СДВГ, как на поведенческом, так и на физиологическом уровнях, машинное обучение может применяться для определения принадлежности к одному из нескольких традиционно выделяемых подтипов: с преобладанием невнимательности, с преобладанием гиперактивности-импульсивности или смешанному. Индивидуальные различия в проявлениях СДВГ требуют персонализированного подхода, а значит, и разработки методов, способных учитывать эти различия.

Ахмади и коллеги [10] использовали методы глубокого обучения для классификации людей с СДВГ и без него, а также для определения подтипов: комбинированного (смешанного) и подтипа с дефицитом внимания. В качестве источника данных авторы использовали сырой сигнал ЭЭГ, из которого извлекли пространственные и частотные характеристики. В результате точность модели для комбинации Бета- и Гамма-ритмов составила 99,6%.

Тенев с соавторами [26] для определения подтипов СДВГ применяли спектральный анализ мощности основных ритмов ЭЭГ. В их исследовании использовались данные для четырех различных состояний участников: фон с открытыми глазами, фон с закрытыми глазами, а также при выполнении двух нейропсихоло-

гических тестов — на внимание и на эмоциональное состояние. В качестве классификатора был использован метод опорных векторов (SVM), который продемонстрировал свою эффективность, выявляя различия в вычислительной ЭЭГ для различных подгрупп в рамках одного синдрома.

Парк и коллеги [11] в своем исследовании с использованием фМРТ анализировали различия в функциональной связности между различными областями мозга. Меры связности затем использовались в качестве характеристик для классификатора на основе метода опорных векторов (SVM). Наиболее значимые различия между подтипами СДВГ были выявлены в лобных, поясных и теменных областях коры, а также частично в височных, затылочных областях и мозжечке. Точность классификатора для различения подтипов СДВГ составила 91,18% для парадигм.

Краткие выводы

Учитывая специфику работы с физиологическими и нейроанатомическими данными, связанную с трудоемкостью их сбора, а также их мультипараметрический характер, наиболее точные результаты обычно дает применение SVM-классификатора, хорошо работающего для небольших датасетов и шумных данных.

Для тех случаев, когда доступны наборы данных с большим количеством участников, значимых уровней точности, специфичности и чувствительности можно достичь с помощью глубокого обучения.

Значительных успехов в классификации многие авторы добились даже в отношении подтипов СДВГ, поведенчески различных и требующих различных интервенций.

Дальнейший рост точности классификации и улучшение перспективы экстраполяции результатов обучения моделей на общую популяцию возможно обеспечить, если, с одной стороны, увеличить выборки участников с СДВГ и контрольных групп для проверки

устойчивости полученных моделей, и, с другой стороны, объединять данные различных модальностей в одном наборе данных, повышая таким образом точность результатов.

Заключение

Методы машинного обучения обладают несколькими значимыми преимуществами при поиске биомаркеров для диагностики СДВГ. Они позволяют обрабатывать большие объемы данных, что способствует нахождению новых закономерностей и признаков, ассоциированных с данным расстройством. Модели машинного обучения способны автоматически обучаться на основе предоставленных данных и адаптироваться к изменяющимся условиям. Кроме того, применение методов искусственного интеллекта в диагностике может сократить время, необходимое для постановки диагноза.

Однако, несмотря на значимые преимущества, машинное обучение имеет и некоторые ограничения: для обучения моделей требуется большой объем данных; кроме того, существует проблема обобщаемости моделей: пространство признаков, созданное на основе обучающих данных, может неадекватно отражать особенности тестовых данных, что приводит к снижению точности классификации. Эти ограничения препятствуют широкому применению машинного обучения в диагностике СДВГ и других расстройств развития, несмотря на высокие показатели точности, специфичности и чувствительности.

Кроме того, возникают вопросы конфиденциальности и безопасности при обработке медицинских данных, требующих особого внимания и соответствующих мер безопасности. Несмотря на значительные и обнадеживающие достижения, методы машинного обучения требуют дальнейших усовершенствований и валидации перед тем, как их можно будет применять в клинической практике.

Литература

1. Храмов А.Е., Короновский А.А. Непрерывный вейвлетный анализ и его приложения. М.: Физико-математическая литература, 2003. 174 с.
2. Applicable features of electroencephalogram for ADHD diagnosis / A. Khaleghi, P.M. Birgani, M.F. Fooladi, M.R. Mohammadi // Research on Biomedical Engineering. 2020. Vol. 36. P. 1—11. DOI:10.1007/s42600-019-00036-9
3. Ariel R., Castel A.D. Eyes wide open: enhanced pupil dilation when selectively studying important information // Experimental Brain Research. 2014. Vol. 232. P. 337—344. DOI:10.1007/s00221-013-3744-5
4. Automatic brain caudate nuclei segmentation and classification in diagnostic of attention-deficit/hyperactivity disorder / L. Igual, J.C. Soliva, S. Escalera, R Gimeno, O. Vilarroya, P. Radeva // Computerized Medical Imaging and Graphics. 2012. Vol. 36. № 8. P. 591—600. DOI:10.1016/j.compmedimag.2012.08.002
5. Brainstem abnormalities in attention deficit hyperactivity disorder support high accuracy individual diagnostic classification / B.A. Johnston, B. Mwangi, K. Matthews, D. Coghill, K. Konrad, J.D. Steele // Human Brain Mapping. 2014. Vol. 35. № 10. P. 5179—5189. DOI:10.1002/hbm.22542
6. Choi S., Jang Y., Kim H. A Deep Learning Approach to Imputation of Dynamic Pupil Size Data and Prediction of ADHD // International Journal on Artificial Intelligence Tools. 2023. Vol. 32. № 6. Article ID 2350020. DOI:10.1142/S0218213023500203

7. Chugh N., Aggarwal S., Balyan A. The Hybrid Deep Learning Model for Identification of Attention-Deficit/Hyperactivity Disorder Using EEG // *Clinical EEG and Neuroscience*. 2024. Vol. 55. № 1. P. 22—33. DOI:10.1177/15500594231193511
8. Classification of ADHD patients on the basis of independent ERP components using a machine learning system / Mueller A., G. Candrian, J.D. Kropotov, V.A. Ponomarev, G.M. Baschera // *Nonlinear Biomedical Physics*. 2010. Vol. 4. Suppl 1. Article ID S1. 12 p. DOI:10.1186/1753-4631-4-S1-S1
9. Clinical Validation of Eye Vergence as an Objective Marker for Diagnosis of ADHD in Children / P. Varela Casal, F. Lorena Esposito, I. Morata Mart nez [et al.] // *Journal of attention disorders*. 2019. Vol. 23. № 6. P. 599—614. DOI:10.1177/1087054717749931
10. Computer aided diagnosis system using deep convolutional neural networks for ADHD subtypes / A. Ahmadi, M. Kashefi, H. Shahrokhi, M.A. Nazari // *Biomedical Signal Processing and Control*. 2021. Vol. 63. Article ID 102227. DOI:10.1016/j.bspc.2020.102227
11. Connectivity Analysis and Feature Classification in Attention Deficit Hyperactivity Disorder Sub-Types: A Task Functional Magnetic Resonance Imaging Study / B.Y. Park, M. Kim, J. Seo, J.M. Lee, H. Park // *Brain topography*. 2016. Vol. 29. P. 429—439. DOI:10.1007/s10548-015-0463-1
12. Das W., Khanna S. A Robust Machine Learning Based Framework for the Automated Detection of ADHD Using Pupillometric Biomarkers and Time Series Analysis // *Scientific Reports*. 2021. Vol. 11. Article ID 16370. 12 p. DOI:10.1038/s41598-021-95673-5
13. Deep neural network technique for automated detection of ADHD and CD using ECG signal / H.W. Loh, C.P. Ooi, S.L. Oh, P.D. Barua, Y.R. Tan, F. Molinari, S. March, U.R. Acharya, D.S.S. Fung // *Computer methods and programs in biomedicine*. 2023. Vol. 241. Article ID 107775. 8 p. DOI:10.1016/j.cmpb.2023.107775
14. Detecting ADHD Based on Brain Functional Connectivity Using Resting-State MEG Signals / N. Hamedi, A. Khadem, M. Delrobaei, A. Babajani-Feremi // *Frontiers in Biomedical Technologies*. 2022. Vol. 9. № 2. P. 110—118. DOI:10.18502/fbt.v9i2.8850
15. Diagnosis of Attention Deficit Hyperactivity Disorder with combined time and frequency features / M. Altınkaynak, N. Dolu, A. Güven, F. Pektaş, S. Özmen, E. Demirci, M. zetoğlu // *Biocybernetics and Biomedical Engineering*. 2020. Vol. 40. № 3. P. 927—937. DOI:10.1016/j.bbe.2020.04.006
16. Discriminating between ADHD adults and controls using independent ERP components and a support vector machine: a validation study / A. Mueller, G. Candrian, V. A. Grane, J.D. Kropotov, V.A. Ponomarev, G.M. Baschera // *Nonlinear Biomedical Physics*. 2011. Vol. 5. Article ID 5. 18 p. DOI:10.1186/1753-4631-5-5
17. Disorder-specific predictive classification of adolescents with attention deficit hyperactivity disorder (ADHD) relative to autism using structural magnetic resonance imaging / L. Lim, A. Marquand, A.A. Cubillo, A.B. Smith, K. Chantiluke, A. Simmons, M. Mehta, K. Rubia // *PLoS ONE*. 2013. Vol. 8. № 5. Article ID e63660. 10 p. DOI:10.1371/journal.pone.0063660
18. Efficient Feature Selection and Machine Learning Based ADHD Detection Using EEG Signal / M. Maniruzzaman, J. Shin, M.A.M. Hasan, A. Yasumura // *Computers, Materials & Continua*. 2022. Vol. 72. № 3. P. 5179—5195. DOI:10.32604/cmc.2022.028339
19. Extreme learning machine-based classification of ADHD using brain structural MRI data / X. Peng, P. Lin, T. Zhang, J. Wang // *PLoS ONE*. 2013. Vol. 8. № 11. Article ID e79476. 12 p. DOI:10.1371/journal.pone.0079476
20. Eye movement behavior in a real-world virtual reality task reveals ADHD in children / L. Merzon, K. Pettersson, E.T. Aronen, H. Huhdanpää, E. Seesjärvi, L. Henriksson, W.J. MacInnes, M. Mannerkoski, E. Macaluso, J. Salmi // *Scientific reports*. 2022. Vol. 12. Article ID 20308. 12 p. DOI:10.1038/s41598-022-24552-4
21. Ghasemi E., Ebrahimi M., Ebrahimie E. Machine learning models effectively distinguish attention-deficit/hyperactivity disorder using event-related potentials // *Cognitive Neurodynamics*. 2022. Vol. 16. 1335—1349. DOI:10.1007/s11571-021-09746-2
22. Identification of attention-deficit hyperactivity disorder based on the complexity and symmetricity of pupil diameter / S. Nobukawa, A. Shirama, T. Takahashi, T. Takeda, H. Ohta, M. Kikuchi, A. Iwanami, N. Kato, S. Toda // *Scientific reports*. 2021. Vol. 11. Article ID 8439. 14 p. DOI:10.1038/s41598-021-88191-x
23. Identifying ADHD boys by very-low frequency prefrontal fNIRS fluctuations during a rhythmic mental arithmetic task / S. Ortuño-Miró, S. Molina-Rodríguez, C. Belmonte, J. Ibañez-Ballesteros // *Journal of Neural Engineering*. 2023. Vol. 20. Article ID 036018. 23 p. DOI:10.1088/1741-2552/acad2b
24. Kasim Ö. Identification of attention deficit hyperactivity disorder with deep learning model // *Physical and engineering sciences in medicine*. 2023. Vol. 46. P. 1081—1090. DOI:10.1007/s13246-023-01275-y
25. Kaur A., Kahlon K.S. Accurate Identification of ADHD among Adults Using Real-Time Activity Data // *Brain Sciences*. 2022. Vol. 12. № 7. Article ID 831. 17 p. DOI:10.3390/brainsci12070831
26. Machine Learning Approach for Classification of ADHD adults / A. Tenev, S. Markovska-Simoska, L. Kocarev, J. Pop-Jordanov, A. Müller, G. Candrian // *International journal of psychophysiology*. 2013. Vol. 93. № 1. P. 162—166. DOI:10.1016/j.ijpsycho.2013.01.008
27. Mafi M., Radfar S. High Dimensional Convolutional Neural Network for EEG Connectivity-Based Diagnosis of ADHD // *Journal of biomedical physics & engineering*. 2022. Vol. 12(6). P. 645—654. DOI:10.31661/jbpe.v0i0.2108-1380

28. Moghaddari M., Lighvan M.Z., Danishvar S. Diagnose ADHD disorder in children using convolutional neural network based on continuous mental task EEG // *Computer Methods and Programs in Biomedicine*. 2020. Vol. 197. Article ID 105738. 11 p. DOI:10.1016/j.cmpb.2020.105738
29. Pupil size tracks attentional performance in attention-deficit/hyperactivity disorder / G. Wainstein, D. Rojas-Líbano, N.A. Crossley, X. Carrasco, F. Aboitiz, T. Ossand n // *Scientific Reports*. 2017. Vol. 7. Article ID 8228. 9 p. DOI:10.1038/s41598-017-08246-w
30. The global prevalence of ADHD in children and adolescents: A systematic review and meta-analysis / N. Salari, H. Ghasemi, N. Abdoli, A. Rahmani, M. Shiri, A. Hashemian, H. Akbari, M. Mohammadi // *Rivista italiana di pediatria = The Italian journal of pediatrics*. 2023. Vol. 49. Article ID 48, 12 p. DOI:10.1186/s13052-023-01456-1

References

1. Khramov A.E., Koronovskii A.A. Nepreryvnyi veivletnyi analiz i ego prilozheniya [Continuous wavelet analysis and its applications]. Moscow: Fiziko-matematicheskaya literatura, 2003. 174 c.
2. Khaleghi A., Birgani P.M., Fooladi M.F., Mohammadi M.R. Applicable features of electroencephalogram for ADHD diagnosis. *Research on Biomedical Engineering*. 2020. Vol. 36, pp. 1—11. DOI:10.1007/s42600-019-00036-9
3. Ariel R., Castel A.D. Eyes wide open: enhanced pupil dilation when selectively studying important information. *Experimental Brain Research*. 2014. Vol. 232, pp. 337—344. DOI:10.1007/s00221-013-3744-5
4. Igual L., Soliva J.C., Escalera S., Gimeno R., Vilarroya O., Radeva P. Automatic brain caudate nuclei segmentation and classification in diagnostic of attention-deficit/hyperactivity disorder. *Computerized Medical Imaging and Graphics*. 2012. Vol. 36, no. 8, pp. 591—600. DOI:10.1016/j.compmedimag.2012.08.002
5. Johnston B.A., Mwangi B., Matthews K., Coghill D., Konrad K., Steele J.D. Brainstem abnormalities in attention deficit hyperactivity disorder support high accuracy individual diagnostic classification. *Human Brain Mapping*. 2014. Vol. 35, no. 10, pp. 5179—5189. DOI:10.1002/hbm.22542
6. Choi S., Jang Y., Kim H. A Deep Learning Approach to Imputation of Dynamic Pupil Size Data and Prediction of ADHD. *International Journal on Artificial Intelligence Tools*. 2023. Vol. 32, no. 6, article ID 2350020. DOI:10.1142/S0218213023500203
7. Chugh N., Aggarwal S., Balyan A. The Hybrid Deep Learning Model for Identification of Attention-Deficit/Hyperactivity Disorder Using EEG. *Clinical EEG and Neuroscience*. 2024. Vol. 55, no. 1, pp. 22—33. DOI:10.1177/15500594231193511
8. Mueller A., Candrian G., Kropotov J.D., Ponomarev V.A., Baschera G.M. Classification of ADHD patients on the basis of independent ERP components using a machine learning system. *Nonlinear Biomedical Physics*. 2010. Vol. 4. Suppl 1, article ID S1. 12 p. DOI:10.1186/1753-4631-4-S1-S1
9. Varela Casal P., Lorena Esposito F., Morata Martínez I. et al. Clinical Validation of Eye Vergence as an Objective Marker for Diagnosis of ADHD in Children / P. Varela Casal, F. Lorena Esposito, I. Morata Martínez [et al.]. *Journal of attention disorders*. 2019. Vol. 23, no. 6, pp. 599—614. DOI:10.1177/1087054717749931
10. Ahmadi A., Kashefi M., Shahrokhi H., Nazari M.A. Computer aided diagnosis system using deep convolutional neural networks for ADHD subtypes. *Biomedical Signal Processing and Control*. 2021. Vol. 63, article ID 102227. DOI:10.1016/j.bspc.2020.102227
11. Park B.Y., Kim M., Seo J., Lee J.M., Park H. Connectivity Analysis and Feature Classification in Attention Deficit Hyperactivity Disorder Sub-Types: A Task Functional Magnetic Resonance Imaging Study. *Brain topography*. 2016. Vol. 29, pp. 429—439. DOI:10.1007/s10548-015-0463-1
12. Das W., Khanna S. A Robust Machine Learning Based Framework for the Automated Detection of ADHD Using Pupillometric Biomarkers and Time Series Analysis. *Scientific Reports*. 2021. Vol. 11, article ID 16370. 12 p. DOI:10.1038/s41598-021-95673-5
13. Loh H.W., Ooi C.P., Oh S.L., Barua P.D., Tan Y.R., Molinari F., March S., Acharya U.R., Fung D.S.S. Deep neural network technique for automated detection of ADHD and CD using ECG signal. *Computer methods and programs in biomedicine*. 2023. Vol. 241, article ID 107775. 8 p. DOI:10.1016/j.cmpb.2023.107775
14. Hamedi N., Khadem A., Delrobaei M., Babajani-Feremi A. Detecting ADHD Based on Brain Functional Connectivity Using Resting-State MEG Signals. *Frontiers in Biomedical Technologies*. 2022. Vol. 9, no. 2, pp. 110—118. DOI:10.18502/ft.v9i2.8850
15. Altınkaynak M., Dolu N., Güven A., Pektaş F., Özmen S., Demirci E., İzzetoğlu M. Diagnosis of Attention Deficit Hyperactivity Disorder with combined time and frequency features. *Biocybernetics and Biomedical Engineering*. 2020. Vol. 40, no. 3, pp. 927—937. DOI:10.1016/j.bbe.2020.04.006
16. Mueller A., Candrian G., V. Grane A., Kropotov J.D., Ponomarev V.A., Baschera G.M. Discriminating between ADHD adults and controls using independent ERP components and a support vector machine: a validation study. *Nonlinear Biomedical Physics*. 2011. Vol. 5, article ID 5. 18 p. DOI:10.1186/1753-4631-5-5
17. Lim L., Marquand A., Cubillo A.A., Smith A.B., Chantiluke K., Simmons A., Mehta M., Rubia K. Disorder-specific predictive classification of adolescents with attention deficit hyperactivity disorder (ADHD) relative to autism using

- structural magnetic resonance imaging. *PLoS ONE*. 2013. Vol. 8, no. 5, article ID e63660. 10 p. DOI:10.1371/journal.pone.0063660
18. Maniruzzaman M., Shin J., Hasan M.A.M., Yasumura A. Efficient Feature Selection and Machine Learning Based ADHD Detection Using Signal EEG. *Computers, Materials & Continua*. 2022. Vol. 72, no. 3, pp. 5179—5195. DOI:10.32604/cm.2022.028339
19. Peng X., Lin P., Zhang T., Wang J. Extreme learning machine-based classification of ADHD using brain structural MRI data. *PLoS ONE*. 2013. Vol. 8, no. 11, article ID e79476. 12 p. DOI:10.1371/journal.pone.0079476
20. Merzon L., Pettersson K., Aronen E.T., Huhdanpää H., Seesjärvi E., Henriksson L., MacInnes W.J., Mannerkoski M., Macaluso E., Salmi J. Eye movement behavior in a real-world virtual reality task reveals ADHD in children. *Scientific reports*. 2022. Vol. 12, article ID 20308. 12 p. DOI:10.1038/s41598-022-24552-4
21. Ghasemi E., Ebrahimi M., Ebrahimie E. Machine learning models effectively distinguish attention-deficit/hyperactivity disorder using event-related potentials. *Cognitive Neurodynamics*. 2022. Vol. 16. 1335—1349. DOI:10.1007/s11571-021-09746-2
22. Nobukawa S., Shirama A., Takahashi T., Takeda T., Ohta H., Kikuchi M., Iwanami A., Kato N., Toda S. Identification of attention-deficit hyperactivity disorder based on the complexity and symmetricity of pupil diameter. *Scientific reports*. 2021. Vol. 11, article ID 8439. 14 p. DOI:10.1038/s41598-021-88191-x
23. Ortuño-Miró S., Molina-Rodríguez S., Belmonte C., Ibañez-Ballesteros J. Identifying ADHD boys by very-low frequency prefrontal fNIRS fluctuations during a rhythmic mental arithmetic task. *Journal of Neural Engineering*. 2023. Vol. 20, article ID 036018. 23 p. DOI:10.1088/1741-2552/acad2b
24. Kasim Ö. Identification of attention deficit hyperactivity disorder with deep learning model. *Physical and engineering sciences in medicine*. 2023. Vol. 46, pp. 1081—1090. DOI:10.1007/s13246-023-01275-y
25. Kaur A., Kahlon K.S. Accurate Identification of ADHD among Adults Using Real-Time Activity Data. *Brain Sciences*. 2022. Vol. 12, no. 7, article ID 831. 17 p. DOI:10.3390/brainsci12070831
26. Tenev A., Markovska-Simoska S., Kocarev L., Pop-Jordanov J., Müller A., Candrian G. Machine Learning Approach for Classification of ADHD adults. *International journal of psychophysiology*. 2013. Vol. 93, no. 1, pp. 162—166. DOI:10.1016/j.ijpsycho.2013.01.008
27. Mafi M., Radfar S. High Dimensional Convolutional Neural Network for EEG Connectivity-Based Diagnosis of ADHD. *Journal of biomedical physics & engineering*. 2022. Vol. 12(6), pp. 645—654. DOI:10.31661/jbpe.v0i0.2108-1380
28. Moghaddari M., Lighvan M.Z., Danishvar S. Diagnose ADHD disorder in children using convolutional neural network based on continuous mental task EEG. *Computer Methods and Programs in Biomedicine*. 2020. Vol. 197, article ID 105738. 11 p. DOI:10.1016/j.cmpb.2020.105738
29. Wainstein G., Rojas-Lbano D., Crossley N.A., Carrasco X., Aboitiz F., Ossand n T. Pupil size tracks attentional performance in attention-deficit/hyperactivity disorder. *Scientific Reports*. 2017. Vol. 7, article ID 8228. 9 p. DOI:10.1038/s41598-017-08246-w
30. Salari N., Ghasemi H., Abdoli N., Rahmani A., Shiri M., Hashemian A., Akbari H., Mohammadi M. The global prevalence of ADHD in children and adolescents: A systematic review and meta-analysis. *Rivista italiana di pediatria = The Italian journal of pediatrics*. 2023. Vol. 49, article ID 48, 12 p. DOI:10.1186/s13052-023-01456-1

Информация об авторах

Сологуб Полина Сергеевна, аспирант, Санкт-Петербургский государственный университет (ФГБОУ ВО СПбГУ), г. Санкт-Петербург, Российская Федерация, ORCID: <https://orcid.org/0009-0004-1928-2690>, e-mail: polinesku@gmail.com

Information about the authors

Polina S. Sologub, PhD Student, Saint Petersburg State University, Saint Petersburg, Russia, ORCID: <https://orcid.org/0009-0004-1928-2690>, polinesku@gmail.com

Получена 03.05.2024

Принята в печать 25.06.2024

Received 03.05.2024

Accepted 25.06.2024