

ТЕХНИКАЛЫҚ ҒЫЛЫМДАР / ТЕХНИЧЕСКИЕ НАУКИ /
TECHNICAL SCIENCES

DOI 10.54596/2958-0048-20206-3-262-271

УДК 004.93:616.8

МРНТИ 28.23.15

**МЕТОДЫ ЦИФРОВОЙ ОБРАБОТКИ СИГНАЛОВ ЭЭГ И МАШИННОГО
ОБУЧЕНИЯ ДЛЯ ОЦЕНКИ КОГНИТИВНЫХ СОСТОЯНИЙ ЧЕЛОВЕКА**

Ибраева М.А.^{1*}, Герасимова Ю.В.¹

^{1*}НАО «Северо-Казахстанский университет имени Манаша Козыбаева»,
Петропавловск, Казахстан

*Автор для корреспонденции: moldir.ibrayeva1801@gmail.com

Аннотация

В статье рассматриваются методы цифровой обработки электроэнцефалографических сигналов и алгоритмы машинного обучения, применяемые для оценки когнитивных состояний человека на основе открытого набора ЭЭГ-данных. Электроэнцефалография является одним из наиболее информативных неинвазивных методов исследования функциональной активности головного мозга, однако анализ ЭЭГ-сигналов осложняется низким отношением сигнал/шум, межиндивидуальной вариативностью и наличием артефактов различной природы.

Исследование выполнено с использованием открытого набора ЭЭГ-данных, зарегистрированных при выполнении когнитивных задач, связанных с креативным мышлением. Программный конвейер обработки включает этапы полосовой и режекторной фильтрации, подавления артефактов, спектрального анализа в стандартных частотных диапазонах, а также анализа функциональной связности на основе метрик фазовой синхронизации. На основе полученных характеристик формируется вектор признаков, используемый для классификации когнитивных состояний с применением методов машинного обучения.

Экспериментальные результаты показывают, что комбинирование спектральных и функционально связанных признаков позволяет повысить точность классификации когнитивных состояний по сравнению с использованием только спектральных характеристик. Полученные результаты подтверждают перспективность применения методов цифровой обработки ЭЭГ и машинного обучения для автоматизированной оценки когнитивных состояний человека.

Ключевые слова: электроэнцефалография, когнитивные состояния, цифровая обработка сигналов, функциональная связность, машинное обучение.

**АДАМНЫҢ КОГНИТИВТІК КҮЙЛЕРІН БАҒАЛАУҒА АРНАЛҒАН ЭЭГ
СИГНАЛДАРЫН ЦИФРЛЫҚ ӨНДЕУ ЖӘНЕ МАШИНАЛЫҚ ОҚЫТУ
ӘДІСТЕРІ**

Ибраева М.А.^{1*}, Герасимова Ю.В.¹

^{1*}«Манаш Қозыбаев атындағы Солтүстік Қазақстан университеті» КеАҚ,
Петропавл, Қазақстан

*Хат-хабар үшін автор: moldir.ibrayeva1801@gmail.com

Аңдатпа

Бұл жұмыста ашық қолжетімді электроэнцефалографиялық деректер жиынтығын пайдалана отырып, адамның когнитивтік күйлерін бағалауға арналған ЭЭГ сигналдарын цифрлық өңдеу әдістері мен машиналық оқыту алгоритмдері қарастырылады. Электроэнцефалография мидың функционалдық

белсенділігін зерттеудің инвазивті емес және жоғары уақыттық ажыратымдылыққа ие әдістерінің бірі болып табылады, алайда ЭЭГ деректерін талдау шудың, артефактілердің және жеке ерекшеліктердің әсерінен күрделене түседі.

Зерттеу барысында ЭЭГ сигналдарын сүзгілеу, артефактілерді басу, спектрлік талдау және фазалық синхронизацияға негізделген функционалдық байланыстылықты бағалау қамтылған бағдарламалық өңдеу конвейері қолданылды. Алынған спектрлік және байланыстылық белгілерін біріктіру машиналық оқыту алгоритмдері арқылы когнитивтік күйлерді жіктеу дәлдігін арттыратыны көрсетілді.

Кілт сөздер: электроэнцефалография, когнитивтік күйлер, сигналдарды цифрлық өңдеу, функционалдық байланыстылық, машиналық оқыту.

METHODS OF DIGITAL EEG PROCESSING AND MACHINE LEARNING FOR ASSESSING HUMAN COGNITIVE STATES

M.A. Ibrayeva^{1*}, Y.V. Gerasimova¹

^{1*}*Manash Kozybayev North Kazakhstan University NPLC, Petropavlovsk, Kazakhstan*

^{*}*Corresponding author: moldir.ibrayeva1801@gmail.com*

Abstract

This paper presents methods of digital processing of electroencephalographic (EEG) signals and machine learning algorithms for assessing human cognitive states based on an open-access EEG dataset. Electroencephalography is a widely used non-invasive technique for studying brain functional activity due to its high temporal resolution. However, EEG signal analysis is challenged by low signal-to-noise ratio, inter-subject variability, and the presence of artifacts, which necessitates the use of advanced digital signal processing methods.

The study employs an open EEG dataset recorded during the performance of cognitive tasks associated with creative thinking. The proposed processing pipeline includes band-pass and notch filtering, artifact suppression, spectral analysis in standard frequency bands, and functional connectivity analysis based on phase synchronization metrics. Spectral and connectivity features are combined to form an informative feature space for machine learning-based classification of cognitive states.

Experimental results demonstrate that the joint use of spectral characteristics and functional connectivity measures improves classification accuracy compared to the use of spectral features alone. The obtained results confirm the effectiveness of digital EEG processing and machine learning methods for automated assessment of cognitive states and highlight their potential for further development of real-time cognitive monitoring systems.

Keywords: EEG, cognitive states, digital signal processing, functional connectivity, machine learning.

Введение

В последние десятилетия наблюдается устойчивый рост интереса к исследованию когнитивных состояний человека с использованием неинвазивных нейрофизиологических методов. Одним из наиболее распространённых и информативных таких методов является электроэнцефалография (ЭЭГ), позволяющая регистрировать электрическую активность головного мозга с высокой временной разрешающей способностью. Благодаря этим особенностям ЭЭГ широко применяется в нейронауке, клинической диагностике, исследованиях интерфейсов «мозг–компьютер», а также в задачах мониторинга когнитивных и психоэмоциональных состояний человека.

Сигналы ЭЭГ отражают сложные нелинейные процессы, связанные с синхронизацией и взаимодействием нейронных ансамблей коры головного мозга. При этом анализ ЭЭГ существенно осложняется низким отношением сигнал/шум, высокой межиндивидуальной вариативностью, а также наличием артефактов различной природы, включая мышечную активность, движения глаз и внешние электромагнитные помехи. В

связи с этим эффективное исследование когнитивных состояний на основе ЭЭГ требует применения современных методов цифровой обработки сигналов, направленных на повышение качества данных и извлечение информативных признаков [1].

Особый интерес в рамках современных исследований представляет анализ креативности как когнитивного состояния, связанного с процессами генерации и оценки новых идей. Креативность играет ключевую роль в научной, инженерной и образовательной деятельности, однако до настоящего времени остаётся сложной для объективной количественной оценки. Нейрофизиологические исследования показывают, что креативное мышление сопровождается специфическими изменениями ЭЭГ-активности, прежде всего в альфа-диапазоне, а также динамической перестройкой функциональной связности между различными областями мозга, включая лобные и теменные зоны [2]. В ряде работ подчёркивается, что анализ только локальных спектральных характеристик ЭЭГ не всегда позволяет в полной мере описать сложную организацию когнитивных процессов. В этой связи всё большее внимание уделяется анализу функциональной связности ЭЭГ, рассматривающему мозг как распределённую сеть взаимодействующих нейронных систем. Показано, что изменения в паттернах функциональной связности являются чувствительными маркерами когнитивных состояний и могут служить информативными признаками при их классификации [3].

Дополнительные возможности для автоматизированной оценки когнитивных состояний открывает применение методов машинного обучения. Алгоритмы классификации позволяют выявлять сложные закономерности в многомерных наборах признаков и обеспечивают более высокую точность распознавания когнитивных состояний по сравнению с традиционными статистическими подходами. Исследования показывают, что использование комбинированных наборов признаков, включающих как спектральные характеристики, так и показатели функциональной связности, способствует повышению эффективности классификации когнитивных и креативных состояний [4].

Целью настоящей работы является исследование методов цифровой обработки ЭЭГ и алгоритмов машинного обучения для оценки когнитивных состояний человека на основе открытого набора данных. В работе анализируется информативность спектральных характеристик и показателей функциональной связности ЭЭГ, а также оценивается их эффективность при классификации когнитивных состояний, связанных с креативным мышлением.

Материалы и методы исследования

Описание набора данных. В работе использовался открытый набор ЭЭГ-данных [5]. Представленный набор данных включает сигналы ЭЭГ, зарегистрированные во время выполнения участниками творческих заданий. В эксперименте участвовали 29 студентов. Сигналы ЭЭГ регистрировались с помощью 64-канального BrainVision actiCHamp с частотой дискретизации 500 Гц.

Эксперимент был основан на модифицированной версии теста Торренса на креативное мышление. Участникам предлагалось 3 незаконченных наброска, и выполнить 3 различные упражнения на креативность: генерация идей, развитие идей и оценку идей. На этапе генерации идей, участником требовалось завершить эскиз на основе первоначальных впечатлений. Задание на оценку идеи предполагало создание рисунка, отличающегося от начального варианта. Каждой эпохе ЭЭГ-сигнала сопоставляется метка класса, определяемая экспериментальной разметкой. Каждая эпоха рассматривается как независимое наблюдение, что позволяет существенно увеличить

объем обучающей выборки и повысить устойчивость моделей. Задача машинного обучения в данной работе формулируется как задача бинарной классификации когнитивных состояний на основе ЭЭГ-сигналов.

В соответствии с экспериментальным протоколом выделяются два класса: генерация идей - состояние спонтанного, дивергентного мышления, характеризующееся активным поиском и созданием новых идей; оценка идей - аналитическое состояние, связанное с проверкой, сравнением и отбором решений.

Обучающая выборка формируется путём сегментации непрерывных ЭЭГ-записей на временные эпохи фиксированной длительности. Для каждой эпохи рассчитывается вектор признаков и соответствующая метка класса. Разметка данных основана на экспериментальных метках, синхронизированных с выполнением креативных заданий. Такой подход обеспечивает высокую достоверность целевых меток, однако не исключает возможных переходных состояний между классами, что дополнительно усложняет задачу классификации.

Предварительная обработка сигналов ЭЭГ. Цель предварительной обработки сигналов заключается в повышении отношения сигнал-шум и приведении данных к форме, пригодной для последующего количественного и статистического анализа. На этом этапе осуществляется подавление медленных дрейфов, высокочастотных шумов, сетевых помех, а также нормализация пространственной структуры многоканальных данных.

Предварительная обработка выполняется над непрерывными сигналами и является критически важной, поскольку ошибки на этом этапе могут привести к искажению спектральных характеристик и ложным выводам при анализе когнитивных процессов.

Первым этапом обработки является полосовая фильтрация сигналов в диапазоне от 0 до 40 Гц. Выбор данного диапазона обусловлен нейрофизиологическими и практическими соображениями. Нижняя граница фильтрации (0 Гц) позволяет эффективно подавить медленные дрейфы базовой линии, возникающие вследствие изменения сопротивления на границе электрод-кожа, а также артефакты, связанные с медленными движениями головы и тела. Верхняя граница (40 Гц) ограничивает вклад высокочастотных шумов, включая электромиографические (ЭМГ) артефакты, которые особенно выражены в диапазоне выше 40–50 Гц.

Фильтрация реализуется с использованием FIR-фильтра с оконной функцией. Применение FIR-фильтров обеспечивает линейную фазовую характеристику, что особенно важно при анализе временных и фазовых параметров ЭЭГ, так как позволяет избежать искажений формы сигнала и временных сдвигов между каналами.

При регистрации ЭЭГ в лабораторных и квазилабораторных условиях существенную роль играют сетевые помехи, обусловленные наводками от электрической сети. В рассматриваемой системе частота сети составляет 50 Гц, что требует применения режекторного фильтра.

Удаление артефактов. Даже после полосовой и режекторной фильтрации ЭЭГ-сигналы, как правило, содержат остаточные артефакты, связанные с движением глаз (EOG), мышечной активностью (EMG), а также нестабильной работой отдельных электродов. Наличие таких артефактов может существенно исказить спектральные и связностные характеристики сигналов, что особенно критично при анализе когнитивных процессов и обучении моделей машинного обучения.

Для подавления артефактов, связанных с движением глаз, используется независимый компонентный анализ (ICA). Метод ICA позволяет разложить

многоканальный сигнал на набор статистически независимых компонент, часть из которых соответствует артефактам.

Спектральный анализ сигналов ЭЭГ. Спектральный анализ ЭЭГ-сигналов выполнялся с целью извлечения признаков, отражающих распределение мощности сигнала по частотным диапазонам. Для каждой временной эпохи вычислялась спектральная плотность мощности с использованием быстрого преобразования Фурье. На основе полученных спектров рассчитывались значения мощности в стандартных частотных диапазонах: тета- (4–7 Гц), альфа- (8–13 Гц) и бета-диапазонах (14–30 Гц). Выбор указанных диапазонов обусловлен их нейрофизиологической значимостью при анализе когнитивных процессов и, в частности, креативного мышления, что подтверждается результатами ранее проведённых исследований [2]. Полученные спектральные характеристики нормализовались и использовались в качестве признаков для последующего анализа.

Анализ функциональной связности сигналов ЭЭГ. Креативные когнитивные процессы характеризуются координацией активности между различными областями мозга. Для описания этих взаимодействий используется анализ функциональной связности.

Когерентность отражает степень линейной взаимосвязи сигналов в частотной области и рассчитывается для каждой пары каналов. Для повышения устойчивости результатов используется усреднение когерентности в заданных частотных диапазонах.

Показатель Phase Locking Value (PLV) используется для оценки фазовой согласованности сигналов. PLV позволяет выявлять нелинейные формы взаимодействия, не фиксируемые методами линейного анализа.

В анализ включены пары электродов, соответствующие лобно-теменным и межполушарным связям: F3–F4, F3–P3, F4–P4, Fz–Pz, C3–C4. Выбор данных пар был основан на априорных нейрофизиологических представлениях о креативном мышлении как процессе, включающем взаимодействие лобных областей, связанных с контролем, планированием и оценкой идей, и теменных областей, участвующих в интеграции сенсорной и ассоциативной информации.

Формирование и отбор признаков. После выполнения этапов предварительной обработки, удаления артефактов и анализа ЭЭГ-сигналов для каждой эпохи формируется вектор признаков, предназначенный для последующего использования в алгоритмах машинного обучения. Вектор признаков объединяет информацию о локальной активности отдельных каналов и о взаимодействии между различными областями мозга.

В соответствии с реализованным программным конвейером, в состав вектора признаков включены следующие группы характеристик: Спектральные признаки, отражающие распределение мощности сигнала в стандартных частотных диапазонах. Эти признаки характеризуют локальную активность корковых областей и широко применяются при анализе когнитивных состояний; Относительные спектральные показатели рассчитывались как отношение мощности соответствующего частотного диапазона к суммарной мощности спектра и использовались для приведения признаков к сопоставимому масштабу; Нелинейные характеристики, в частности спектральная энтропия, которая отражает степень сложности и распределённости спектральной энергии сигнала; Признаки функциональной связности, рассчитанные для заранее выбранных пар каналов (F3–F4, F3–P3, F4–P4, C3–C4, Fz–Pz) с использованием спектральной когерентности и показателя фазовой синхронизации (PLV).

Комбинация спектральных и связностных признаков позволяет учитывать как локальные изменения активности мозга, так и взаимодействие между различными функциональными областями, что является принципиально важным при анализе креативных когнитивных процессов. Используемые признаки приведены в таблице 1.

Таблица 1. Таблица признаков

Признак	Каналы	Метрика
coh_F3_F4	F3–F4	Coherence, PLV
coh_F3_P3	F3–P3	Coherence, PLV
coh_F4_P4	F4–P4	Coherence, PLV
coh_C3_C4	C3–C4	Coherence, PLV
coh_FZ_PZ	Fz–Pz	Coherence, PLV
delta_power	Bce	мощность 1–4 Гц
theta_power	Bce	мощность 4–7 Гц
alpha_power	Bce	мощность 8–13 Гц
beta_power	Bce	мощность 14–30 Гц
relative_alpha	Bce	α/total
relative_theta	Bce	θ/total
relative_beta	Bce	β/total
spectral_entropy	Bce	спектральная энтропия
alpha_peak	Bce	$\max \alpha$

Результаты исследования и их обсуждение

В рамках настоящего исследования решалась задача классификации когнитивных состояний человека на основе электроэнцефалографических данных. В качестве входных данных использовались векторы признаков, сформированные на основе спектральных характеристик ЭЭГ и показателей функциональной связности. Каждое наблюдение соответствовало отдельной временной эпохе ЭЭГ-сигнала, ассоциированной с выполнением когнитивной задачи. Задача классификации формулировалась как задача обучения с учителем, где каждому вектору признаков сопоставлялась метка когнитивного состояния, определяемая экспериментальным протоколом открытого набора данных.

В качестве базового алгоритма в данной работе используется логистическая регрессия, которая широко применяется в задачах классификации. В работе также используются нелинейные методы машинного обучения, а именно метод опорных векторов с радиально-базисным ядром (SVM с RBF-ядром) и метод случайного леса

Для оценки качества классификации используются следующие метрики: Точность (Accuracy) – доля правильно классифицированных объектов от общего числа наблюдений; F1-мера – гармоническое среднее между точностью (precision) и полнотой (recall), позволяющее учитывать баланс между количеством правильно распознанных объектов целевого класса и полнотой их обнаружения; AUC ROC (Area Under the Receiver Operating Characteristic Curve) – площадь под ROC-кривой, характеризующая

способность модели разделять классы при различных значениях порога принятия решения.

Для оценки устойчивости результатов классификации использовалась стратифицированная 5-кратная кросс-валидация. На каждом разбиении обучающая и тестовая выборки формировались с сохранением соотношения классов. Для каждой модели рассчитывались средние значения метрик Ассигасу, F1-мера и AUC, а также стандартные отклонения по фолдам кросс-валидации.

На первом этапе экспериментов классификация когнитивных состояний проводилась с использованием только спектральных признаков ЭЭГ. В качестве признаков использовались показатели мощности сигналов в тета-, альфа- и бета-диапазонах, рассчитанные для отдельных каналов ЭЭГ.

На следующем этапе в вектор признаков были дополнительно включены показатели функциональной связности ЭЭГ, рассчитанные на основе метрик фазовой синхронизации между парами каналов. Такой подход позволил учитывать не только локальные изменения активности мозга, но и особенности взаимодействия между различными его областями. Результаты показали, что включение признаков функциональной связности приводит к повышению точности классификации когнитивных состояний по сравнению с использованием только спектральных характеристик (с 60% до 80%). Это свидетельствует о том, что функциональная связность содержит дополнительную информацию о когнитивных процессах, не отражаемую локальными спектральными показателями [6]. Полученные результаты подтверждают представление о когнитивных состояниях как о результатах распределённой сетевой активности мозга [7, 8].

В таблице 2 представлены результаты оценки качества классификации для трёх моделей машинного обучения: логистической регрессии (LogReg), метода опорных векторов (SVM) и случайного леса (RF). В качестве метрик использовались точность (ассигасу), F1-мера и площадь под ROC-кривой (AUC).

Таблица 2. Метрики классификации при 5-кратной кросс-валидации

Модель	Точность $\pm$ SD	F1-мера $\pm$ SD	AUC $\pm$ SD
LogReg	0.768 ± 0.025	0.770 ± 0.026	0.826 ± 0.016
SVM	0.813 ± 0.017	0.819 ± 0.018	0.889 ± 0.012
RF	0.830 ± 0.010	0.832 ± 0.009	0.915 ± 0.006

Логистическая регрессия показала наименьшие значения всех рассмотренных метрик: точность составила 0.768 ± 0.025 , F1-мера – 0.770 ± 0.026 , AUC – 0.826 ± 0.016 . Это указывает на ограниченную способность линейной модели учитывать сложные нелинейные зависимости в пространстве ЭЭГ-признаков.

Модель SVM с RBF-ядром продемонстрировала более высокое качество классификации по сравнению с логистической регрессией: точность составила 0.813 ± 0.017 , F1-мера – 0.819 ± 0.018 , AUC – 0.889 ± 0.012 . Полученные результаты свидетельствуют о большей эффективности нелинейной модели при работе с высокоразмерными и коррелированными признаками.

Наилучшие показатели были достигнуты с использованием алгоритма случайного леса. Для данной модели значения точности, F1-меры и AUC составили 0.830 ± 0.010 , 0.832 ± 0.009 и 0.915 ± 0.006 соответственно. Это позволяет сделать вывод о том, что

ансамблевые методы, основанные на решающих деревьях, эффективно выявляют сложные нелинейные зависимости в данных ЭЭГ и обеспечивают устойчивое качество классификации.

На рисунке 1 представлено сравнение ROC-кривых для моделей логистической регрессии, метода опорных векторов с RBF-ядром и алгоритма случайного леса. ROC-кривые отражают зависимость доли истинно положительных решений (TPR) от доли ложноположительных решений (FPR) при изменении порога классификации.




Рисунок 1. ROC кривые

ROC-кривые на рисунке 1 построены по результатам отдельного тестового разбиения данных, поэтому значения AUC на графике могут незначительно отличаться от средних значений AUC, полученных при 5-кратной кросс-валидации. В частности, для отдельного тестового разбиения AUC составили 0.819 для логистической регрессии, 0.897 для SVM-RBF и 0.931 для случайного леса. В таблице 2 представлены усреднённые значения AUC по фолдам кросс-валидации, которые являются более устойчивой оценкой качества моделей.

Заключение

В настоящей работе исследованы методы цифровой обработки электроэнцефалографических сигналов и алгоритмы машинного обучения для оценки когнитивных состояний человека на основе открытого набора ЭЭГ-данных. В ходе исследования был реализован программный конвейер анализа ЭЭГ, включающий этапы предварительной фильтрации, подавления артефактов, спектрального анализа и анализа

функциональной связности. Продemonстрировано, что включение показателей функциональной связности, рассчитанных на основе метрик фазовой синхронизации, позволяет повысить точность классификации когнитивных состояний по сравнению с использованием только спектральных характеристик. Полученные результаты подтверждают представление о когнитивных состояниях как о результатах распределённой сетевой активности мозга и подчёркивают значимость анализа взаимодействий между различными областями мозга.

Наилучшие показатели были достигнуты с использованием алгоритма случайного леса. При стратифицированной 5-кратной кросс-валидации для данной модели значения Ассигасу, F1-меры и AUC составили 0.830 ± 0.010 , 0.832 ± 0.009 и 0.915 ± 0.006 соответственно. Это позволяет сделать вывод о том, что ансамблевые методы, основанные на решающих деревьях, эффективно выявляют сложные нелинейные зависимости в данных ЭЭГ и обеспечивают устойчивое качество классификации.

Результаты исследования могут быть использованы в дальнейшем при разработке систем мониторинга когнитивных состояний и нейрофизиологических исследований, ориентированных на анализ креативного мышления. Перспективными направлениями дальнейших работ являются расширение используемых наборов данных, исследование устойчивости моделей машинного обучения и адаптация разработанных методов к условиям реального времени.

Литература:

1. Мутикумар Н., Раджендран Н., Сринивасан Р. Недавние достижения в обработке сигналов электроэнцефалографии (ЭЭГ): обзор методов и приложений // Сенсоры. – 2023. – Т. 23, № 16. – С. 6434. <https://doi.org/10.3390/s23166434>.
2. Финк А., Бенедек М. Мощность альфа-ритма ЭЭГ и креативная идеация // Нейронаука и биоповеденческие обзоры. – 2014. – Т. 44. – С. 111–123.
3. Халеги Н., Хашеми Ш., Пейванди М., Зафарманди Ардабили С., Бехджати М., Шейхиванд С., Данишвар С. Анализ функциональной связности ЭЭГ при аномалиях головного мозга: систематический обзор // Информатика в медицине: открытый доступ. – 2024. – Т. 47. – С. 101476.
4. Стивенс К.Э., Забелина Д.Л. Классификация креативности: применение методов машинного обучения к ЭЭГ-данным дивергентного мышления // Нейроизображение. – 2020. – Т. 219. – С. 116990.
5. Зангене Соруш М., Чжао М., Цзя В., Цзэн Я. Исходные ЭЭГ-записи креативного мышления в задачах проектирования (модифицированный тест креативности Торренса ТТСТ-F). – 2023.
6. Халеги Н., Хашеми Ш., Пейванди М., Ардабили С.З., Бехджати М., Шейхиванд С., Данишвар С. Анализ функциональной связности ЭЭГ при аномалиях головного мозга: систематический обзор // Информатика в медицине: открытый доступ. – 2024. – Т. 47. – С. 101476.
7. Се В., Толл Р.Т., Нельсон Ч.А. Анализ функциональной связности ЭЭГ в пространстве источников // Развивающая когнитивная нейронаука. – 2022. – Т. 56. – С. 101119.
8. Ромингер К., Папоушек И., Перхтольд К.М., Бенедек М., Вайс Э.М., Вебер Б., Швердтфегер А. Р., Эглофф Б., Финк А. Функциональная связность мозговых сетей во время генерации и разработки креативных идей // NeuroImage. – 2020. – Т. 207. – С. 116395. <https://doi.org/10.1016/j.neuroimage.2019.116395>.

References:

1. Mutikumar, T., Rajendran, N., & Srinivasan, R. (2023). Recent advances in electroencephalography (EEG) signal processing: A review of methods and applications. *Sensors*, 23(16), 6434. <https://doi.org/10.3390/s23166434>
2. Fink, A., & Benedek, M. (2014). EEG alpha power and creative ideation. *Neuroscience and Biobehavioral Reviews*, 44, 111–123.

3. Khaleghi, N., Hashemi, S., Peyvandi, M., Zafarmandi Ardabili, S., Behjati, M., Sheikhivand, S., & Danishvar, S. (2024). EEG functional connectivity analysis in brain disorders: A systematic review. *Informatics in Medicine Unlocked*, 47, 101476.
4. Stevens, C.E., & Zabelina, D.L. (2020). Creativity classification: Applying machine learning methods to EEG data of divergent thinking. *NeuroImage*, 219, 116990.
5. Zangeneh Soroush, M., Zhao, M., Jia, W., & Zeng, Y. (2023). Raw EEG recordings of creative thinking in design tasks (modified Torrance Tests of Creative Thinking, TTCT-F).
6. Khaleghi, N., Hashemi, S., Peyvandi, M., Zafarmandi Ardabili, S., Behjati, M., Sheikhivand, S., & Danishvar, S. (2024). EEG functional connectivity analysis in brain disorders: A systematic review. *Informatics in Medicine Unlocked*, 47, 101476.
7. Xie, W., Toll, R.T., & Nelson, C.A. (2022). Source-space EEG functional connectivity analysis. *Developmental Cognitive Neuroscience*, 56, 101119.
8. Rominger K., Papousek I., Perchtold C.M., Benedek M., Weiss E. M., Weber B., Schwerdtfeger A.R., Egloff B., Fink A. Functional connectivity of brain networks during the generation and elaboration of creative ideas // *NeuroImage*. – 2020. – Vol. 207. – P. 116395. <https://doi.org/10.1016/j.neuroimage.2019.116395>.

Information about the authors

M.A. Ibrayeva – graduate student, Department of Energetics and Radioelectronics, Manash Kozybayev North Kazakhstan University NPLC, Petropavlovsk; e-mail: moldir.ibrayeva1801@gmail.com;

Y.V. Gerasimova – corresponding author, Associate Professor of the Department of Energetics and Radioelectronics, Manash Kozybayev North Kazakhstan University NPLC, Petropavlovsk; e-mail: julyvic@mail.ru; ORCID: 0000-0003-1877-383X.