



Подход к воспроизводимому анализу согласованности данных нейровизуализации с использованием открытых программных средств

¹ А.К. Зверева, ORCID: 0009-0000-5568-2086 <zvereva.ak@phystech.edu>

^{1, 2} А.В. Грабовой, ORCID: 0000-0002-4031-0025 <grabovoy.av@phystech.edu>

¹ М.С. Каприелова, ORCID: 0009-0001-3837-5698 <kaprielova.ms@phystech.edu>

¹ Московский физико-технический институт (МФТИ),
Россия, 141701, Московская область, г. Долгопрудный, Институтский переулок, д.9.

² Институт проблем управления имени В. А. Трапезникова РАН,
Россия, 117997, Москва, Профсоюзная улица, 65, стр. 1.

Аннотация. В работах, связанных с анализом данных из нескольких источников, возникает задача гармонизации представлений, устраняющей расхождения, обусловленные техническими особенностями сбора. Мы описываем воспроизводимый программный конвейер для данных многоэховой функциональной МРТ (фМРТ), нацеленный на приведение сигналов от различных эхо-каналов к согласованному латентному пространству. Конвейер основан на открытых данных и инструментах (BIDS, DataLad) и включает этапы предобработки, формирования временных окон и обучения легких моделей выравнивания представлений. Эффективность оценивается протоколом на основе приращения межэховой корреляции первой главной компоненты ($\Delta PC1$). На выборке из 100 сессий, при фиксированной конфигурации процедур и гиперпараметров, медианный прирост $\Delta PC1$ составил $\approx +0.11$, доля сессий с положительным эффектом $\approx 61\%$, что подтверждает умеренный, но устойчивый выигрыш; 95%-й доверительный интервал медианы не включает ноль. Представленный конвейер служит открытой воспроизводимой базовой линией для сравнения с более сложными методами гармонизации.

Ключевые слова: программный конвейер; воспроизводимый анализ; согласованность данных; выравнивание представлений; многоэховая фМРТ; нейровизуализация; латентные представления; DataLad; BIDS.

Для цитирования: Зверева А.К., Грабовой А.В., Каприелова М.С. Подход к воспроизводимому анализу согласованности данных нейровизуализации с использованием открытых программных средств. Труды ИСП РАН, том 38, вып. 3, часть 1, 2026 г., стр. 269–282. DOI: 10.15514/ISPRAS-2026-38(3)-17.

A Reproducible Approach to the Analysis of Data Consistency in Neuroimaging Using Open-Source Tools

¹A.K. Zvereva, ORCID: 0009-0000-5568-2086 <zvereva.ak@phystech.edu>

^{1,2}A.V. Grabovoy, ORCID: 0000-0002-4031-0025 <grabovoy.av@phystech.edu>

¹M.S. Kapriellova, ORCID: 0009-0001-3837-5698 <kapriellova.ms@phystech.edu>

¹*Moscow Institute of Physics and Technology (MIPT),
9, Institutsky Lane, Dolgoprudny, Moscow Region, 141701, Russia.*

²*Institute of Control Sciences RAS,
65, Profsoyuznaya st., Moscow, 117997, Russia.*

Abstract. Studies involving multi-source data analysis often require representation harmonization to address discrepancies caused by technical differences in data acquisition. We describe a reproducible software pipeline for multi-echo functional MRI (fMRI) data, aimed at mapping signals from different echo channels into a common, aligned latent space. The pipeline is based on open data and tools (BIDS, DataLad) and includes preprocessing, time-windowing, and training of lightweight representation alignment models. Efficacy is evaluated using a protocol based on the gain in inter-echo first principal component ($\Delta PC1$) correlation. Using a sample of 100 sessions with a fixed configuration of procedures and hyperparameters, the median $\Delta PC1$ gain was $\approx +0.11$, and the proportion of sessions with a positive effect was $\approx 61\%$, confirming a moderate but consistent improvement. The 95% bootstrap CI for the median does not include zero. This pipeline serves as an open, reproducible baseline for comparison against more complex harmonization methods.

Keywords: software pipeline; reproducible analysis; data agreement; representation alignment; multi-echo fMRI; neuroimaging; latent representations; DataLad; BIDS.

For citation: Zvereva A.K., Grabovoy A.V., Kapriellova M.S. An Approach for Reproducible Analysis of Neuroimaging Data Agreement Using Open-Source Tools. *Trudy ISP RAN/Proc. ISP RAS*, vol. 38, issue 3, part 1, 2026. pp. 269-282 (in Russian). DOI: 10.15514/ISPRAS-2026-38(3)-17.

1. Введение

При анализе данных, полученных из нескольких источников или в различных условиях, возникает задача гармонизации их представлений. Эта задача является центральной для междисциплинарной области выравнивания представлений (representational alignment), изучающей способы сопоставления латентных пространств биологических и искусственных систем [1]. Это необходимо для того, чтобы алгоритмы машинного обучения могли выявлять содержательные закономерности, а не обучаться на артефактах, вызванных техническими различиями в сборе данных [2, 3]. Проблема технических артефактов и межсайтовой гармонизации признана критической для надежности выводов в нейровизуализации [3]. Более того, высокая вариативность в конвейерах обработки данных создает дополнительные риски для воспроизводимости, что требует создания прозрачных и открытых инструментов анализа. В области нейровизуализации данная задача является особенно актуальной, в частности, при работе с данными многоэховой функциональной МРТ (фМРТ), где сигналы от разных эхо-каналов имеют различные статистические свойства [4] (рис. 1).

Одним из возможных способов решения является применение сложных моделей глубокого обучения для совместного анализа разнородных сигналов. В последние годы активно развиваются подходы, связывающие согласованность представлений в искусственных и биологических системах восприятия, включая анализ выравнивания латентных признаков моделей с fMRI-активностью человеческого мозга [1, 5–6]. Подобные работы демонстрируют, что корректное сопоставление латентных пространств не только улучшает воспроизводимость фМРТ-анализов, но и способствует интерпретируемости моделей нейровизуализации. Однако, несмотря на потенциал таких подходов, их практическое применение и сравнение сопряжено с рядом трудностей:




Рис. 1. Пример данных многоэховой фМРТ. Средние изображения для одного испытуемого (sub-01), полученные на (a) первом (Эхо 1) и (b) втором (Эхо 2) эхо-каналах.

Заметны различия в контрасте и интенсивности сигнала, иллюстрирующие исходную рассогласованность данных между эхо-каналами.

Fig. 1. Example of multi-echo fMRI data. Mean images for a single subject (sub-01) from (a) the first (Echo 1) and (b) the second (Echo 2) echo channels. Visible differences in contrast and signal intensity illustrate the inherent misalignment between echo channels.

- Проблема воспроизводимости. Многие исследования представляют итоговые метрики, но не предоставляют полного доступа к программному коду и конвейеру обработки данных. Это затрудняет верификацию результатов и использование предложенных методов в качестве отправной точки для дальнейших работ [7].
- Отсутствие стандартных базовых решений (baselines). Для оценки эффективности нового, сложного метода гармонизации необходимо сравнивать его с простыми, но надёжными и полностью воспроизводимыми решениями. На практике такие общедоступные «линейки» для оценки качества выравнивания представлений часто отсутствуют [8].
- Высокая сложность. Внедрение и адаптация сложных моделей требует значительных вычислительных ресурсов и временных затрат, а их эффективность на малых выборках фМРТ ограничена [9]. Примером может служить обработка многоэховых данных, которая требует применения специализированных программных конвейеров, таких как tedana, для разделения BOLD и не-BOLD компонентов сигнала. Даже недавние исследования, направленные на строгое сравнение методов, вынуждены реализовывать и сопоставлять отдельные, сложные пайплайны для одно- и многоэховых данных, что подчеркивает отсутствие простого универсального решения [10].

В данной работе для решения обозначенных проблем мы предлагаем подход, основанный на создании и апробации полностью воспроизводимого программного конвейера для анализа и гармонизации данных. Конвейер автоматизирует все этапы: от загрузки открытых данных с помощью системы контроля версий DataLad [11] до обучения легковесных моделей выравнивания и расчёта метрик согласованности. Такой подход позволяет не только получить количественную оценку эффекта гармонизации, но и предоставляет научному сообществу прозрачное и легко адаптируемое базовое решение для будущих исследований. В частности, аналогичные усилия по созданию воспроизводимых сред для анализа фМРТ/МРТ-данных описаны в работе Распределенная модульная платформа «Цифровая Лаборатория» как среда для проведения научных исследований и разработок НИЦ «Курчатовский Институт» [12], что подчёркивает актуальность темы открытых и воспроизводимых инструментов в нейровизуализации. Актуальность создания подобных вычислительных конвейеров для генерации и анализа виртуальных наборов данных подтверждается и в смежных областях биомедицинского анализа, например, при моделировании данных пульсовой волны [13].

Работа устроена следующим образом. В разделе 2 мы описываем используемые данные и этапы их предобработки. Раздел 3 посвящён описанию реализованных методов выравнивания представлений и протоколу оценки их эффективности. В разделе 4 представлены результаты, полученные на открытом наборе данных. Раздел 5 содержит обсуждение полученных результатов и ограничений предложенного подхода. Выводы по результатам исследования сделаны в разделе 6.

2. Данные и предобработка

В данном разделе описывается источник данных, ключевые параметры их сбора, а также программный конвейер, реализованный для их загрузки и подготовки к анализу.

2.1 Источник данных

В качестве источника данных был использован открытый набор ds003592, размещенный в репозитории OpenNeuro [14]. Набор данных содержит данные структурной и многоэховой функциональной МРТ, полученные от 301 здорового взрослого участника двух возрастных групп. Для настоящего исследования использовались данные фМРТ покоя (resting-state fMRI) и соответствующие им анатомические T1w-взвешенные изображения.

2.2 Параметры сбора данных

Сбор данных проводился на двух площадках (Site 1, Site 2) с незначительными различиями в параметрах МРТ-сканеров. Для анализа были задействованы следующие типы изображений:

- 1) T1w (анатомические данные):
 - Site 1: TR = 2530 мс, TE = 3.4 мс, размер вокселя = 1 мм изотропный.
 - Site 2: TR = 1900 мс, TE = 2.52 мс, размер вокселя = 1 мм изотропный.
- 2) Rest (функциональные данные):
 - Site 1: TR = 3000 мс, TE = 13.7/30/47 мс, размер вокселя = 3 мм изотропный.
 - Site 2: TR = 3000 мс, TE = 14/29.96/45.92 мс, размер вокселя = 3.4×3.4×3 мм.

Для нашего анализа, направленного на выравнивание представлений между эхо-каналами, из каждой сессии использовались данные первых двух эхо (например, TE ≈ 14 мс и TE ≈ 30 мс).

2.3 Программный конвейер предобработки

Для обеспечения воспроизводимости и эффективного управления данными был реализован программный конвейер, включающий следующие шаги:

- 1) Загрузка данных. Для загрузки данных применялась система контроля версий DataLad, интегрированная с системой управления файлами git-annex. Такой подход позволил организовать выборочную загрузку только необходимых для анализа файлов: анатомических T1w-изображений (anat/*T1w.nii.gz) и функциональных данных для первого и второго эхо (func/*_echo-1/2_bold.nii.gz).
- 2) Подготовка окон. Временные ряды фМРТ для каждого эхо-канала разрезались на пересекающиеся окна фиксированной длины. Для основного анализа использовались окна длиной T = 8 временных срезов (TR), что соответствует 24 секундам, с шагом в 2 среза (6 секунд). Данные в каждом окне нормализовались (z-score), что является стандартной практикой в конвейерах статистического анализа [15]. Для унификации пространственного разрешения и снижения вычислительной сложности проводился передискретизация каждого окна до воксельной сетки размером 80×80×24. В итоговых расчетах, представленных в разделе 4, использовались окна длиной T=8 TR для обеспечения стабильности оценки главной компоненты.

3. Методы

После подготовки данных был проведён сравнительный анализ, целью которого являлась количественная оценка эффекта от применения легковесных процедур выравнивания латентных представлений. В данном разделе описывается базовая линия для сравнения, сами процедуры выравнивания, а также протокол метрик, использованный для оценки их эффективности.

3.1 Базовый уровень согласованности

В качестве базового уровня согласованности (baseline) была принята корреляция между сигналами первого и второго эхо на необработанных данных. Для каждого временного окна вычислялась главная компонента (PC1) пространственного распределения активности вокселей. [16] Затем между векторами PC1 для первого (PC1_echo1) и второго (PC1_echo2) эхо рассчитывался коэффициент корреляции Пирсона [17, 18]. Это значение, обозначенное как PC1_{before}, характеризует исходную степень схожести сигналов до применения каких-либо моделей выравнивания.

3.2 Процедуры выравнивания представлений

Для обоснования выбора реализованных моделей в табл. 1 приведено сравнение предложенного подхода с существующими альтернативами в области гармонизации и выравнивания фМРТ. Мы фокусируемся на методах, пригодных для работы внутри сессии без привлечения внешних меток или больших обучающих выборок. Для повышения согласованности между эхо-каналами были апробированы два класса методов, широко обсуждаемых в литературе по гармонизации данных. К первому классу относятся статистические (линейные) методы, распределения данных. Ко второму – методы на основе обучения представлений, использующие, например, автоэнкодеры для извлечения гармонизированных признаков [19]. В нашей работе мы реализуем и сравниваем простой линейный подход (Ridge-регрессия) [20] и современный метод сопоставления представлений (VICReg) [21, 22].

3.2.1 Линейное выравнивание

Данный подход предполагает, что представление одного эхо-канала может быть аппроксимировано линейным преобразованием представления другого канала. В работе была обучена модель (Ridge-регрессия), находящая матрицу преобразования W , которая минимизирует среднеквадратичную ошибку между преобразованным сигналом первого эхо ($X_1 \cdot W$) и сигналом второго эхо (X_2). Для предотвращения переобучения и получения объективной оценки, модели обучались и тестировались на непересекающихся подмножествах данных.

3.2.2 Выравнивание на основе сопоставления представлений

Задача выравнивания представлений между субъектами или каналами активно исследуется в нейровизуализации и включает методы совместного обучения латентных пространств [23, 24]. Эти подходы направлены на формирование общего функционального пространства мозга, в котором индивидуальные вариации представлены как аффинные преобразования. В данном исследовании эта идея адаптирована к многоэховым данным фМРТ с применением VICReg-обучения для сопоставления представлений между эхо-каналами. Для гармонизации латентных представлений был применен метод выравнивания на основе сопоставления представлений обучения VICReg (Variance-Invariance-Covariance Regularization).

Табл. 1. Сравнительный анализ методологических характеристик подходов к гармонизации и выравниванию представлений данных фМРТ.

Table 1. Comparative Analysis of Methodological Characteristics for fMRI Data Representation Harmonization and Alignment Approaches.

Подход / Метод	Тип преобразования	Основная область применения	Преимущества	Ограничения	Источник
ComBat / Статистические методы	Линейное (параметрическое)	Межсайтовая гармонизация (Site-effects)	Высокая скорость, простота интерпретации	Плохо работает с нелинейными шумами	[2-3]
Hyperalignment (HA / SHA)	Прокрустово / Нелинейное	Межсубъектное выравнивание признаков	Высокая точность в задачах классификации	Чувствительность к парадигме стимулов	[1, 23]
ICA-based (анализ независимых компонент)	Статистическая декомпозиция	Удаление артефактов (шума)	Не требует пространственного выравнивания	Сложность автоматической идентификации компонент	[24]
Ridge Regression (Линейный бейзлайн)	Линейное (регуляризованное)	Предсказание сигнала / Выравнивание	Минимум гиперпараметров, устойчивость	Не учитывает сложные взаимодействия каналов	[9, 20]
VICReg (Предложенный подход)	Нелинейное (SSL / Нейросети)	Межэховая гармонизация представлений	Инвариантность к источнику, отсутствие коллапса признаков	Требует настройки архитектуры энкодера	[6, 22, 25]
GNN / Transformers	Графовое / Attention-based	Моделирование динамики графа связей	Учет топологии и длинных зависимостей	Высокая вычислительная сложность	[26, 27]
Generative (Diffusion / Swin)	Стохастическое (диффузионное)	Синтез данных, робастная гармонизация	Моделирование сложных распределений	Риск генерации галлюцинаций	[28]

Подход основан на использовании «сиамской» архитектуры [25, 29], состоящей из двух идентичных по архитектуре и параметрам 3D «сиамских» свёрточных энкодеров f_θ . Каждый энкодер отображает входное временное окно x из соответствующего эхо-канала в латентное представление (эмбединг) $z = f_\theta(x)$ (рис. 2). Обучение модели заключается в минимизации композитной функции потерь L , которая вычисляется на партии парных представлений Z и Z' , полученных из первого и второго эхо-каналов соответственно:

$$L(Z, Z') = \lambda \cdot s(Z, Z') + \mu \cdot (v(Z) + v(Z')) + \nu \cdot (c(Z) + c(Z')).$$

Здесь λ , μ и ν – гиперпараметры, взвешивающие вклад каждого из трёх компонентов:

- 1) Компонент инвариантности $s(Z, Z')$: обеспечивает инвариантность представлений к источнику сигнала (эхо-каналу). Он минимизирует евклидово расстояние между парными эмбедингами и определяется как среднеквадратичная ошибка (MSE).
- 2) Компонент дисперсии $v(Z)$: противодействует коллапсу представлений (representational collapse), сохраняя дисперсию каждого измерения векторного представления. Данный член функции потерь штрафует модель, если стандартное отклонение векторов вдоль оси признаков в партии падает ниже целевого значения γ .
- 3) Компонент ковариации $c(Z)$: способствует декорреляции признаков в латентном пространстве, снижая избыточность информации. Этот член минимизирует внедиагональные элементы ковариационной матрицы, вычисленной по векторным представлениям в партии.

Совместная оптимизация этих трёх компонентов позволяет модели формировать латентные представления, которые являются одновременно согласованными между эхо-каналами, информативными и не избыточными.




Рис. 2. Принципиальная схема конвейера выравнивания представлений. Входные временные окна из двух эхо-каналов (Эхо 1 и Эхо 2) параллельно обрабатываются двумя идентичными («сиамскими») 3D свёрточными энкодерами. Модель, обученная с помощью функции потерь VICReg, преобразует их в согласованные латентные представления (z_1 и z_2). Эффективность выравнивания оценивается путем расчета схожести (корреляции PC1) между этими итоговыми представлениями.

Fig. 2. Schematic diagram of the representation alignment pipeline. Input time windows from the two echo channels (Echo 1 and Echo 2) are processed in parallel by two identical ('Siamese') 3D convolutional encoders. The model, trained using the VICReg loss function, transforms them into aligned latent representations (z_1 and z_2). The alignment performance is then evaluated by calculating the similarity (PC1 correlation) between these final representations.

3.3 Протокол оценки и метрики

Для количественной оценки эффективности реализованных процедур был разработан протокол, включающий следующие метрики:

- 1) Корреляция после выравнивания ($PC1_{after}$): после применения обученной модели (линейной или на основе сопоставления представлений) к данным в окнах, снова рассчитывалась корреляция главных компонент между преобразованными представлениями эхо-каналов.
- 2) Прирост корреляции ($\Delta PC1$): основная метрика, отражающая эффект от выравнивания. Рассчитывается как разница между корреляцией после и до применения модели: $\Delta PC1 = PC1_{after} - PC1_{before}$.
- 3) Доля улучшений: процент сессий, для которых наблюдался положительный прирост корреляции ($\Delta PC1 > 0$).

Для визуализации распределения результатов по всем сессиям строились гистограмма и коробчатая диаграмма (boxplot) для метрики $\Delta PC1$.

4. Результаты

В данном разделе представлены результаты апробации описанных в Разделе 3 методов (Ridge-регрессия и VICReg) на выборке из 100 сессий фМРТ. Основной целью было получение количественной оценки эффекта от применения процедур выравнивания представлений.

4.1 Результаты линейного выравнивания (контрольный метод)

Анализ линейного выравнивания (Ridge-регрессия) проводился на репрезентативной подвыборке из первых 12 сессий. Данный метод не показал устойчивого положительного эффекта. Медианный прирост согласованности ($\Delta PC1$) составил -0.09, при доле сессий с положительным эффектом около 33%.

Хотя на отдельных сессиях наблюдалось улучшение (вплоть до $\Delta PC1 = +0.41$), общий нейтральный или отрицательный результат для простой линейной модели указывает на то, что артефакты и расхождения между эхо-каналами имеют более сложную, нелинейную природу. Этот результат был принят в качестве базового для сравнения с более сложной моделью.

4.2 Результаты выравнивания на основе сопоставления представлений (VICReg)

Основная апробация проводилась с использованием нелинейной модели VICReg на полной выборке из 100 сессий. В отличие от линейного подхода, данный метод продемонстрировал стабильный положительный эффект.

- Медианное улучшение согласованности по всей выборке составило $+0.11$.
- Доля сессий с положительным эффектом ($\Delta PC1 > 0$) составила 61%.

Среднее значение прироста корреляции также было положительным и составило $+0.114$.

Полученные данные свидетельствуют о том, что простая линейная аппроксимация недостаточна для решения задачи гармонизации. В то же время, применение нелинейной нейросетевой модели (VICReg) позволило получить стабильный и статистически значимый положительный результат.

4.3 Анализ распределения (VICReg)

Для детального анализа распределения полученных результатов была построена гистограмма изменений $\Delta PC1$ (рис. 3).

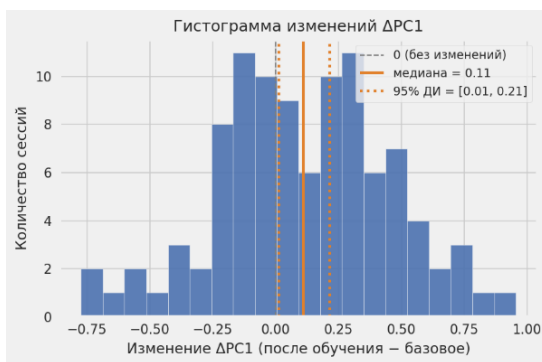


Рис. 3. Гистограмма распределения прироста корреляции ($\Delta PC1$) по 100 сессиям.

Fig. 3. Histogram of correlation gain distribution ($\Delta PC1$) over 100 sessions.

Сплошной линией отмечена медиана ($+0.11$), пунктирной – 95% доверительный интервал для медианы. Как видно из гистограммы, распределение сдвинуто в положительную сторону. Рассчитанный 95% доверительный интервал для медианы составляет $[0.01, 0.21]$. Поскольку данный интервал не включает ноль, можно сделать вывод о статистической значимости наблюдаемого положительного эффекта.

Несмотря на положительную тенденцию в целом, наблюдается значительный разброс результатов. В отдельных сессиях улучшение было существенным (максимальное значение $\Delta PC1$ составило $+0.955$), тогда как в других наблюдалось ухудшение согласованности. Эти данные свидетельствуют о том, что эффективность процедур выравнивания может зависеть от индивидуальных характеристик исходных сигналов.

5. Обсуждение

В данном разделе проводится анализ полученных результатов, обсуждаются их значение и ограничения, а также намечаются направления для дальнейших исследований.

5.1 Интерпретация результатов

Результаты, представленные в Разделе 4, демонстрируют, что предложенный программный конвейер и реализованные в нем легковесные процедуры выравнивания позволяют достичь измеримого положительного эффекта в задаче гармонизации данных многоэховой фМРТ. Медианное улучшение согласованности на уровне +0.11 при доле улучшений в 61% сессий указывает на то, что даже простые модели способны систематически снижать расхождения между эхо-каналами. Статистическая значимость этого эффекта, подтвержденная доверительным интервалом, позволяет утверждать, что наблюдаемый результат не является случайным. Для оценки значимости этого результата мы сопоставили полученный прирост с данными из литературы:

- 1) Сравнение с базовыми линейными моделями. Тот факт, что линейная модель (Ridge-регрессия) показала отрицательный результат (медиана -0.09), подтверждает нелинейную природу расхождений между эхо-каналами. Это коррелирует с выводами El-Gazzar et al. (2023) [3], которые отмечали, что стандартные методы гармонизации (такие как ComBat) часто не дают значимого выигрыша для сложных глубоких моделей, если те способны выучивать инвариантные признаки неявно. Однако в нашем случае неэффективность линейного метода доказывает необходимость явного нелинейного этапа выравнивания.
- 2) Сравнение с методами выравнивания (alignment). Полученный прирост согласованности сопоставим с эффектами, наблюдаемыми в задачах гипервыравнивания (hyperalignment), где использование нелинейных или более сложных оптимизационных решений (например, SHA) приводило к улучшению метрик на 10-19% по сравнению со стандартными методами [23]. Результат текущего исследования в объеме +0.11 (около 11% абсолютного прироста корреляции) находятся в этом же диапазоне, что подтверждает конкурентоспособность предложенного «легковесного» решения.
- 3) Сравнение с SOTA SSL-подходами. Успех архитектуры VICReg в данной задаче подтверждает тренд, заданный в работах по восстановлению изображений из фМРТ (например, MindEye [22]), где контрастивное обучение и сопоставление латентных пространств обеспечили повышение согласованности (alignment) между признаками нейросети и сигналами мозга [6, 22].

При этом значительный разброс значений $\Delta PC1$ (от -0.774 до +0.955) свидетельствует о высокой гетерогенности исходных данных. Как и в работах по «точному функциональному картированию», мы наблюдаем, что наибольшую пользу гармонизация приносит сессиям с исходно низкой корреляцией. Это подчеркивает практическую ценность конвейера как инструмента предобработки, способного «спасти» сессии с низким исходным качеством данных, что является критически важным для задач с малым объемом выборки.

5.2 Основной вклад работы

Ключевым вкладом данной работы является не столько величина достигнутого эффекта, сколько создание и апробация полностью воспроизводимого, открытого программного конвейера. Он решает проблему отсутствия стандартных базовых решений в задачах гармонизации. В следующих работах, в которых предполагается использование более сложных методов выравнивания, представляется возможным использовать представленный

конвейер в качестве стандартной «линейки» для сравнения и объективной оценки прироста эффективности подхода на том же наборе данных.

5.3 Ограничения и направления дальнейшей работы

Несмотря на достигнутые результаты, предложенный подход имеет ряд ограничений, определяющих векторы будущих исследований:

- Чувствительность к гиперпараметрам. Как показал предварительный анализ, амплитуда эффекта уменьшается при переходе от малой выборки к большой. Это указывает на то, что использованные модели с фиксированными гиперпараметрами могут быть неоптимальны для всего разнообразия данных. Дальнейшая работа может включать реализацию автоматического подбора параметров регуляризации для каждой сессии [30]. Помимо классического случайного поиска, перспективным решением является внедрение фреймворков автоматического подбора параметров следующего поколения, таких как Optuna [31], которые позволяют эффективно настраивать сложные архитектуры для биомедицинских данных в условиях ограниченных ресурсов.
- Простота метрики. Корреляция по первой главной компоненте (PC1) является стабильной, но достаточно жесткой метрикой. Она отражает схожесть доминирующего пространственного паттерна, но может быть нечувствительна к более тонким изменениям в сигнале. В будущем следует исследовать и другие, более гибкие метрики схожести латентных представлений, такие как Centered Kernel Alignment (СКА) [32] или методы, основанные на римановой геометрии. Использование методов, учитывающих геометрию пространства признаков, как это успешно применяется для анализа ковариационных матриц ЭЭГ [33] и данных фМРТ [34], могло бы привести к построению более стабильных и согласованных представлений. В будущем также следует рассмотреть методы обобщенного анализа Прокруста (Generalized Procrustes Analysis), которые позволяют находить общую структуру в латентных пространствах более гибко, чем стандартная корреляция [35]. Также важным является переход от глобального выравнивания к локальному функциональному согласованию (Local Functional Alignment), учитывающему индивидуальную вариабельность коры [36].
- Оконный анализ. Анализ проводился на независимых временных окнах. Использование моделей, агрегирующих информацию во времени (например, рекуррентных нейронных сетей), могло бы привести к построению более стабильных и согласованных представлений. Подобные гибридные пространственно-временные архитектуры, сочетающие свёрточные и рекуррентные компоненты, успешно применяются в смежных задачах анализа видеоданных [37-38]. Кроме этого, текущий оконный анализ может быть дополнен моделями, агрегирующими информацию на графах (Graph Neural Networks), что позволяет рассматривать фМРТ не как сетку вокселей, а как динамический граф функциональных связей [26]. Другим вектором является использование предобученных трансформеров для фМРТ (fMRI Transformers), которые демонстрируют высокую эффективность в извлечении признаков из временных рядов в режиме самосупервизируемого обучения [27, 39].

Таким образом, представленный конвейер может служить не только базовым решением, но и платформой для дальнейших экспериментов по исследованию более сложных моделей и метрик.

Перспективным направлением для дальнейшего развития является применение генеративных подходов, в частности, кондиционированных диффузионных моделей [28, 40], для задачи гармонизации. Такой подход позволил бы моделировать не статическое

преобразование, а целый стохастический процесс перехода между латентными представлениями эхо-каналов, что потенциально может привести к созданию более робастных и точных моделей преобразования. Математический аппарат таких моделей, основанный на стохастических дифференциальных уравнениях, открывает возможности для более гибкого и мощного моделирования сложных нелинейных зависимостей в данных нейровизуализации. Также применение архитектур типа Swin-Diffusion [27] позволит моделировать процесс гармонизации эхо-каналов более устойчиво. Дальнейшая стандартизация многоэховых конвейеров должна опираться на актуальные рекомендации по интеграции BOLD-сигнала [41] и учитывать неопределенность при гармонизации данных для повышения клинической значимости результатов. Наконец, развитие масштабируемых моделей SSL на десятках тысяч сканов [42] открывает возможность создания универсальных энкодеров для автоматической очистки многоэховых данных.

6. Заключение

В данной работе был представлен и апробирован подход к созданию воспроизводимого программного конвейера для анализа и гармонизации данных многоэховой фМРТ. Мы продемонстрировали полный цикл работы: от выборочной загрузки открытых данных до применения легковесных моделей выравнивания и количественной оценки их эффективности.

Основным результатом является программная реализация открытого и прозрачного базового решения. Апробация на выборке из 100 сессий показала, что даже простые процедуры выравнивания обеспечивают стабильный положительный эффект, повышая согласованность между эхо-каналами с медианным приростом корреляции +0.11.

Представленный конвейер решает задачу отсутствия стандартных «линеек» для сравнения и может служить как отправной точкой для исследователей, разрабатывающих более сложные методы гармонизации, так и практическим инструментом для предобработки данных.

Программная реализация и результаты анализа доступны в открытом репозитории [43].

Список литературы / References

- [1]. Sucholutsky I., Muttenthaler L., Weller A., Peng A., Bobu A., Kim B., Love B. C., Cueva C. J., Grant E., Groen I., Achterberg J., Tenenbaum J. B., Collins K. M., Hermann K. L., Otkar K., Greff K., Hebart M. N., Cloos N., Kriegeskorte N., Jacoby N., Zhang Q., Marjeh R., Geirhos R., Chen S., Kornblith S., Rane S., Konkle T., O'Connell T. P., Unterthiner T., Lampinen A. K., Müller K.-R., Toneva M., Griffiths T. L. Getting aligned on representational alignment. arXiv preprint arXiv:2310.13018, version 3, 2024. DOI: 10.48550/arXiv.2310.13018.
- [2]. Yu M., Linn K. A., Cook P. A., et al. Statistical harmonization corrects site effects in functional connectivity measurements from multi-site fMRI data. *Human Brain Mapping*, vol. 39, issue 11, 2018, pp. 4213-4227. DOI: 10.1002/hbm.24241.
- [3]. El-Gazzar A., Thomas R. M., van Wingen G. Harmonization techniques for machine learning studies using multi-site functional MRI data. *bioRxiv*, 2023. DOI: 10.1101/2023.06.14.544758.
- [4]. Kundu P., Inati S.J., Evans J.W., Luh W.M., Bandettini P.A. Differentiating BOLD and non-BOLD signals in fMRI time series using multi-echo EPI. *NeuroImage*, vol. 60, issue 3, 2012, pp. 1759-1770. DOI: 10.1016/j.neuroimage.2011.12.028.
- [5]. Davis T., Poldrack R. A. Measuring neural representations with fMRI: practices and pitfalls. *Annals of the New York Academy of Sciences*, vol. 1296, issue 1, 2013, pp. 108-134. DOI: 10.1111/nyas.12156.
- [6]. Lu Z., Wang Y. Teaching CORnet human fMRI representations for enhanced model-brain alignment. *Cognitive Neurodynamics*, vol. 19, 2025, pp. 61-72. DOI: 10.1007/s11571-025-10252-y.
- [7]. Baker M. 1,500 scientists lift the lid on reproducibility. *Nature*, vol. 533, issue 7604, 2016, pp. 452-454. DOI: 10.1038/533452a.
- [8]. Lynch C. J., Elbau I., Liston C. Improving precision functional mapping routines with multi-echo fMRI. *Current Opinion in Behavioral Sciences*, vol. 40, 2021, pp. 113-119. DOI: 10.1016/j.cobeha.2021.03.017.

- [9]. Dorin D., Kiselev N., Grabovoy A., et al. Forecasting fMRI images from video sequences: linear model analysis. *Health Information Science and Systems*, vol. 12, 2024, 55. DOI: 10.1007/s13755-024-00315-5.
- [10]. Giubergia A., Ferrazzi G., Castellaro M., et al. Multi-echo versus single-echo EPI sequences for task-fMRI: A comparative study. *Imaging Neuroscience*, vol. 3, 2025, IMAG.a.94. DOI: 10.1162/IMAG.a.94.
- [11]. Halchenko Y. O., Meyer K., Poldrack B. et al. DataLad: distributed system for joint management of code, data, and their relationship. *Journal of Open Source Software*, vol. 6, issue 63, 2021, 3262. DOI: 10.21105/joss.03262.
- [12]. Поляков А. Н., Енягина И. М., Коковин Д. С. Распределенная модульная платформа «Цифровая Лаборатория» как среда для проведения научных исследований и разработок НИЦ «Курчатовский Институт». *Труды ИСП РАН*, том 32, вып. 5, 2020 г., стр. 143-152. DOI: 10.15514/ISPRAS-2020-32(5)-11. / Polyakov A.N., Enyagina I.M., Kokovin D.S. "Digital Lab" Platform as an Environment for Scientific Research and Development at the Kurchatov Institute. *Trudy ISP RAN/Proc. ISP RAS*, 2020, vol. 32, issue 5, pp. 143-152 (in Russian). DOI: 10.15514/ISPRAS-2020-32(5)-11.
- [13]. Рогов А., Гамилов Т., Брагина А., и др. Synthetic pulse wave dataset for analysis of vascular ageing in elderly patients. *Mathematical Modelling of Natural Phenomena*, 19, 2024, 20. DOI: 10.1051/mmnp/2024017.
- [14]. Spreng R. N., Setton R., Alter U., et al. Neurocognitive aging data release with behavioral, structural, and multi-echo functional MRI measures. *OpenNeuro*, 2022. DOI: 10.18112/openneuro.ds003592.v1.0.13.
- [15]. Friston K. J., Holmes A. P., Worsley K. J., et al. Statistical parametric maps in functional imaging: a general linear approach. *Human Brain Mapping*, vol. 2, issue 4, 1994, pp. 189-210. DOI: 10.1002/hbm.460020402.
- [16]. Friston K. J., Frith C. D., Liddle P. F., Frackowiak R. S. J. Functional connectivity: the principal-component analysis of large (PET) data sets. *Journal of Cerebral Blood Flow & Metabolism*, 1993, vol. 13, issue 1, pp. 5-14. DOI: 10.1038/jcbfm.1993.4.
- [17]. Pearson K. Mathematical Contributions to the Theory of Evolution. III. Regression, Heredity, and Panmixia. *Philosophical Transactions of the Royal Society of London. A*, vol. 187, 1896, pp. 253-318. DOI: 10.1098/rsta.1896.0007.
- [18]. Van Den Heuvel M. P., Pol H. E. H. Exploring the Brain Network: A Review on Resting-State fMRI Functional Connectivity. *European neuropsychopharmacology*, vol. 20, issue 8, 2010, pp. 519-534. DOI: 10.1016/j.euroneuro.2010.03.008.
- [19]. Ingalhalikar M., Shinde S., Karmarkar A., Rajan A., Rangaprakash D., Deshpande G. Functional connectivity-based prediction of Autism on site harmonized ABIDE dataset. *IEEE Transactions on Biomedical Engineering*, vol. 68, issue 11, 2021, pp. 3254-3263. DOI: 10.1109/TBME.2021.3080259.
- [20]. Hoerl A. E., Kennard R. W. Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, vol. 12, issue 1, 1970, pp. 55-67. DOI: 10.1080/00401706.1970.10488634.
- [21]. Sun Y., et al. RSAD: Region-Specific Anomaly Detection in fMRI for Disease Diagnosis. B: *Medical Image Computing and Computer Assisted Intervention – MICCAI 2025. Lecture Notes in Computer Science*, vol 15975. Springer, Cham, 2025, pp. 516-526. DOI: 10.1007/978-3-032-05325-1_46.
- [22]. Scotti P., Banerjee A., Goode J., et al. Reconstructing the Mind's Eye: fMRI-to-Image with Contrastive Learning and Diffusion Priors. In *Proc. of the 37th Conference on Neural Information Processing Systems (NeurIPS)*, 2023, pp 24705-24728.
- [23]. Yousefnezhad M., Selvitella A., Han L., Zhang D. Supervised hyperalignment for multisubject fMRI data alignment. *IEEE Transactions on Cognitive and Developmental Systems*, vol. 13, issue 3, 2020, pp. 475–490. DOI: 10.1109/TCDS.2020.2965981.
- [24]. Anderson A., Dinov I. D., Sherin J. E., Quintana J., Yuille A. L., Cohen M. S. Classification of spatially unaligned fMRI scans. *NeuroImage*, vol. 49, issue 3, 2010, pp. 2509–2519. DOI: 10.1016/j.neuroimage.2009.08.036.
- [25]. Bromley J., Guyon I., LeCun Y., et al. Signature verification using a "siamese" time delay neural network. *Advances in Neural Information Processing Systems*, vol. 6, 1993.
- [26]. Li X., Zhou Y., Dvornek N., et al. Braingnn: Interpretable brain graph neural network for fmri analysis. *Medical Image Analysis*, vol. 74, 2021, 102233. DOI: 10.1016/j.media.2021.102233.
- [27]. Kim, P., Kwon, J., Joo, S., Bae, S., Lee, D., Jung, Y., et al. Swift: Swin 4d fmri transformer. *Advances in Neural Information Processing Systems*, 36, 2023, 42015-42037.
- [28]. Liu, Y., Han, S., Wu, J., Dillenseger, J. L., & Nunes, J. C. Diffusion Model Enhancements for Reliable MRI-to-CT Image Translation. In *synthRad2025 Challenge, MICCAI 2025*.

- [29]. Tran D., Bourdev L., Fergus R., et al. Learning spatiotemporal features with 3d convolutional networks. Proceedings of the IEEE international conference on computer vision, 2015, pp. 4489-4497. DOI: 10.1109/ICCV.2015.510.
- [30]. Bergstra J., Bengio Y. Random search for hyper-parameter optimization. Journal of Machine Learning Research, vol. 13, 2012, pp. 281-305.
- [31]. Akiba T., Sano S., Yanase T., et al. Optuna: A Next-generation Hyperparameter Optimization Framework. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2019, pp. 2623–2631.
- [32]. Kornblith S., Norouzi M., Lee H., et al. Similarity of neural network representations revisited. Proceedings of the 36th International Conference on Machine Learning (ICML), 2019, pp. 3519-3529.
- [33]. Самохина А. М., Нейчев Р. Г., Гончаренко В. В. и др. Модели классификации выборки вызванных потенциалов P300. Системы и Средства Информатики, том 32, вып. 3, 2022 г., стр. 36-49. DOI: 10.14357/08696527220304. / Samokhina A. M., Neychev R. G., Goncharenko V. V., et al. Classification models for P300 evoked potentials. Sistemy i Sredstva Informatiki, 2022, vol. 32, issue 3, pp. 36-49 (in Russian). DOI: 10.14357/08696527220304.
- [34]. Zhao Q., Kwon D., Pohl K.M. A Riemannian Framework for Longitudinal Analysis of Resting-State Functional Connectivity. B: Medical Image Computing and Computer Assisted Intervention – MICCAI 2018. Lecture Notes in Computer Science, vol 11072. Springer, Cham, 2018, pp. 145-153. DOI: 10.1007/978-3-030-00931-1_17.
- [35]. Andreella, A., De Santis, R., Vesely, A. et al. Procrustes-based distances for exploring between-matrices similarity. Stat Methods Appl, 32, 2023, 867-882. DOI: 10.1007/s10260-023-00689-y.
- [36]. Li, C. et al. (2025). Enhancing Cross-Subject fMRI-to-Video Decoding with Global-Local Functional Alignment. In: Leonardi, A., Ricci, E., Roth, S., Russakovsky, O., Sattler, T., Varol, G. (eds) Computer Vision – ECCV 2024. ECCV 2024. Lecture Notes in Computer Science, vol 15141. Springer, Cham. DOI: 10.1007/978-3-031-73010-8_21.
- [37]. Zvereva A. K., Kapriellova M., Grabovoy A. AnomLite: Efficient binary and multiclass video anomaly detection. Results in Engineering, vol. 25, 2025, 104162. DOI: 10.1016/j.rineng.2025.104162.
- [38]. Yin W., Li L., Wu F. X. Deep learning for brain disorder diagnosis based on fMRI images. Neurocomputing, vol. 469, 2022, pp. 332-345. DOI: 10.1016/j.neucom.2020.05.113.
- [39]. Malkiel, I., Rosenman, G., Wolf, L., & Hendler, T. (2021). Pre-training and fine-tuning transformers for fmri prediction tasks. arXiv preprint arXiv:2112.05761, 105.
- [40]. Kazerouni A., Aghdam E. K., Heidari M., et al. Diffusion models for medical image analysis: A comprehensive survey. arXiv preprint arXiv:2211.07804, 2022. DOI: 10.48550/arXiv.2211.07804.
- [41]. DuPre et al. TE-dependent analysis of multi-echo fMRI with tedana. Journal of Open Source Software, 6(66), 3669. DOI: 10.21105/joss.03669.
- [42]. Thomas A., Ré C., Poldrack R. Self-Supervised Learning of Brain Dynamics from Broad Neuroimaging Data. Advances in Neural Information Processing Systems, vol. 35, 2022, pp. 21255-21269.
- [43]. Зверева А. К. fMRI_VicReg: программная реализация и результаты анализа. Доступно по адресу: https://github.com/AnnaZverev/fMRI_VicReg, дата обращения: 12.03.2026.

Информация об авторах / Information about authors

Анна Константиновна ЗВЕРЕВА – аспирант, преподаватель-исследователь, Физтех-школа прикладной математики и информатики (ФПМИ), Национальный исследовательский университет «Московский физико-технический институт» (МФТИ), Россия. Сфера научных интересов включает в себя анализ пространственно-временных рядов, самосупервизируемое обучение, обработка нейровизуализационных данных, воспроизводимые методы анализа данных.

Anna Konstantinovna ZVEREVA – postgraduate student, research and teaching fellow, Phystech School of Applied Mathematics and Informatics (FPMI), National Research University “Moscow Institute of Physics and Technology” (MIPT), Russia. Her research interests include analysis of spatio-temporal data, self-supervised learning, neuroimaging data processing, reproducible data analysis methods.

Андрей Валериевич ГРАБОВОЙ – кандидат физико-математических наук, доцент Кафедры интеллектуальных систем Национального исследовательского университета «Московский физико-технический институт» (МФТИ), Россия, эксперт в Институте проблем управления имени В. А. Трапезникова РАН. Сфера научных интересов включает выбор моделей глубокого обучения, априорные распределения гиперпараметров, дистилляцию знаний (knowledge distillation), обработку естественного языка (NLP) и статистические методы информатики.

Andrey Valerievich GRABOVOY – Cand. Sci. (Phys.-Math.), Associate Professor, Department of Intelligent Systems, National Research University “Moscow Institute of Physics and Technology” (MIPT), Russia, Expert in the Institute of Control Sciences RAS. His research interests include model selection in deep learning, prior distributions of hyperparameters, knowledge distillation, natural-language-processing (NLP), and statistical methods in informatics.

Мариам Семеновна КАПРИЕЛОВА – кандидат технических наук, специалист в области искусственного интеллекта и машинного обучения. Сфера научных интересов включает анализ изображений методами глубокого обучения, обработку мультимодальных сигналов, обучение представлений (representation learning), применение статистических и самосупервизируемых методов в задачах обработки больших массивов данных.

Mariyam Semenovna KAPRIELOVA – Cand. Sci. (Tech.), AI & Machine Learning specialist. Her research interests include image analysis with deep learning, multimodal signal processing, representation learning, and the use of statistical and self-supervised methods for big-data applications.