

# Сравнительный анализ методов сегментации фМРТ изображений, основанных на марковских случайных полях

С. Д. Черняев<sup>1</sup>, О. В. Лукашенко<sup>1,2</sup>

[schernyae@gmail.com](mailto:schernyae@gmail.com) | [lukashenko-oleg@mail.ru](mailto:lukashenko-oleg@mail.ru)

<sup>1</sup>Петрозаводский государственный университет, Петрозаводск, Россия;

<sup>2</sup> Институт прикладных математических исследований Карельского научного центра РАН, Петрозаводск, Россия

Рассматривается задача сегментации трехмерных фМРТ изображений на основе байесовского подхода, где в качестве априорного распределения используется марковское случайное поле (Markov Random Field), а в качестве модели наблюдения – распределение фон Мизеса-Фишера. Основная проблема при применении данного подхода на практике состоит в оценке параметров модели. В статье рассматриваются алгоритмы HMRF-MCEM, HMRF-EM и GrabCut, использующие данную статистическую модель и оценивающие параметры модели без использования заранее размеченных данных. Методы HMRF-EM и GrabCut изначально были предложены в связке с другими статистическими моделями, однако после некоторых модификаций могут быть использованы с распределением фон Мизеса-Фишера. Проведен сравнительный анализ результатов работы алгоритмов на основе экспериментов с использованием синтетических данных, сгенерированных в соответствии со статистической моделью, и реальных фМРТ данных.

Ключевые слова: фМРТ, сегментация, марковское случайное поле, распределение фон Мизеса-Фишера, байесовский вывод

## Comparative Analysis of Methods for Segmentation of fMRI Images Based on Markov Random Fields

S. D. Chernyayev<sup>1</sup>, O. V. Lukashenko<sup>1,2</sup>

[schernyae@gmail.com](mailto:schernyae@gmail.com) | [lukashenko-oleg@mail.ru](mailto:lukashenko-oleg@mail.ru)

<sup>1</sup>Petrozavodsk State University, Petrozavodsk, Russia;

<sup>2</sup>Institute of Applied Mathematical Research of Karelian Research Centre of Russian Academy of Sciences, Petrozavodsk, Russia

The problem of segmentation of three-dimensional fMRI images based on the Bayesian approach is considered, where Markov Random Field is used as the prior distribution, and von Mises-Fisher distribution is used as the observation model. The main problem when applying this approach in practice is an estimation of the model parameters. In this paper, we review algorithms HMRF-MCEM, HMRF-EM and GrabCut, which implement this statistical model and estimate parameters without the usage of the labeled training data. The methods HMRF-EM and GrabCut were introduced in conjunction with other statistical models, but after a small modification, they can be used with the von Mises-Fisher distribution. A comparative study was carried out by performing experiments on both synthetic, generated from the statistical model, and real fMRI data.

Keywords: fMRI, segmentation, Markov random field, von Mises-Fisher distribution, Bayesian inference.

### 1. Введение

Функциональная магнитно-резонансная томография (фМРТ) является важным средством диагностики различных заболеваний, таких, например, как шизофрения, болезнь Альцгеймера и аутизм. Результатом фМРТ является трехмерное изображение, при этом каждому вокселю соответствует вектор значений измеренного сигнала, размерность которого зависит от параметров фМРТ. Сегментация такого рода изображений является важной задачей, так как позволяет автоматически выявлять зоны функциональной активности головного мозга. Как показывают исследования [1], существующие методы иногда приводят к некорректным результатам. Поэтому развитие методов сегментации такого рода изображений, в том числе учитывающих пространственную конфигурацию, является актуальной проблемой.

Стандартным подходом к анализу фМРТ изображений является выбор интересующей области и кор-

реляционный анализ сигналов, соответствующим выделенной области и другим областям мозга. Заданием порогового значения выделяют области с высокой корреляцией. Другие алгоритмы позволяют производить сегментацию без выделения области интереса, используя методы кластерного анализа, например анализ независимых компонент и метод k-средних. Недостатком такого подхода является игнорирование пространственной связи между компонентами, тогда как в реальности функциональные нейронные сети объединены в пространственно согласованные области. Методы, учитывающие пространственную структуру, были предложены в работах [2–4]. Отличительной особенностью этих работ является использование марковских случайных полей (MRF – Markov Random Field) в качестве априорной информации, описывающей пространственные связи между нейронами. Задача сегментации в этом случае сводится к нахождению байесовских оценок. Настоящая работа основана на методе, разрабо-

танном в [3, 4], где используется специфическая модель наблюдения, основанная на распределении фон Мизеса-Фишера. Для оценки параметров модели была разработана итеративная процедура HMRF-МСЕМ (Hidden Markov Random Field – Monte Carlo EM) на основе EM-алгоритма, где математическое ожидание на шаге E аппроксимируется с помощью методов Монте-Карло, что, как правило, приводит к большому объему вычислений. В данной работе предпринята попытка адаптировать для рассматриваемой задачи сегментации фМРТ изображений два других алгоритма: HMRF-EM [5] и GrabCut [6], изначально разработанные для решения других задач и не использующие потенциально затратные в вычислительном плане методы Монте-Карло.

## 2. Скрытые марковские случайные поля

В данном разделе кратко представлен байесовский подход к анализу изображений, где в качестве априорного распределения выступает марковское случайное поле [7, 8].

Пусть задан граф  $G = (V, \mathcal{E})$ , вершины которого соответствуют вокселям изображения, а множество дуг характеризует систему соседства. Рассмотрим многомерную случайную величину  $\mathbf{X} = (X_i, i \in V)$ , у которой элементы  $X_i$  принимают значения из множества меток  $\Lambda = \{1, \dots, L\}$ , где  $L$  – число классов сегментации. Пусть совместное распределение случайного вектора  $\mathbf{X}$  определяется следующим образом:

$$P(\mathbf{x}) = \frac{1}{Z} \exp \left( - \sum_{(i,j) \in \mathcal{E}} V_{i,j}(x_i, x_j) \right), \quad \mathbf{x} \in \Lambda^{|V|}, \quad (1)$$

где  $Z$  – нормировочная константа, а функции  $V_{i,j}$  называются потенциалами дуг. Отметим, что в силу известной теоремы Хаммерслея-Клиффорда [7, 8], случайный вектор, совместное распределение которого задано таким образом, будет марковским случайным полем. Выбор потенциалов зависит от решения конкретной задачи обработки изображений. В данной работе используется стандартная модель Поттса, для которой

$$V_{i,j} = \beta \cdot I(x_i \neq x_j), \quad (2)$$

где  $\beta > 0$ ,  $I$  – индикатор.

Наблюдаемому фМРТ изображению соответствует другой случайный вектор  $\mathbf{Y} = (Y_i, i \in V)$ , элементы которого, в свою очередь, также являются векторами размерности  $p$  (зависит от параметров фМРТ). Условное распределение  $P(\mathbf{y}|\mathbf{x})$  принято называть функцией правдоподобия, для которой выполняется стандартное предположение об условной независимости:

$$P(\mathbf{y}|\mathbf{x}) = \prod_{i \in V} P(y_i|x_i) = \exp \left( - \sum_{i \in V} h_i(x_i, y_i) \right), \quad (3)$$

где  $y_i \in \mathbb{R}^p$ ,  $x_i \in \Lambda$ ,  $h_i(x_i, y_i) = -\ln P(y_i|x_i)$ .

Тогда апостериорное распределение выражается через формулу Байеса:

$$P(\mathbf{x}|\mathbf{y}) \propto P(\mathbf{y}|\mathbf{x})P(\mathbf{y}),$$

и с учетом сделанных предположений окончательно примет следующий вид

$$P(\mathbf{x}|\mathbf{y}) = \frac{1}{Z} \exp(-E(\mathbf{x}|\mathbf{y})),$$

где так называемая энергия изображения определяется следующим образом

$$E(\mathbf{x}|\mathbf{y}) = \sum_{i \in V} h_i(x_i, y_i) + \sum_{(i,j) \in \mathcal{E}} V_{i,j}(x_i, x_j). \quad (4)$$

Такая конструкция получила в литературе название скрытое марковское случайное поле.

Решением задачи сегментации будет являться такая конфигурация  $\mathbf{x}$ , при которой достигается максимум апостериорного распределения (maximum a posteriori):

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \max_{\mathbf{x}} P(\mathbf{x}|\mathbf{y}) = \arg \min_{\mathbf{x}} E(\mathbf{x}|\mathbf{y}). \quad (5)$$

Таким образом, задача нахождения оптимальной сегментации сводится к задаче минимизации энергии, решение которой теоретически может быть найдено с помощью методов дискретной оптимизации. Существует много методов решения оптимизационной задачи (5). В данной работе используются методы, основанные на разрезах графа (Graph Cut), которые в случае бинарной сегментации ( $L = 2$ ) дают точное решение [9], когда функции  $V_{i,j}$  удовлетворяют условию субмодулярности (выполнено для модели Поттса). В случае произвольной сегментации ( $L > 2$ ) существуют итерационные процедуры, сходящиеся к близкому к глобальному оптимуму значению [9], при условии, что функции  $V_{i,j}$  являются метриками на множестве меток  $\Lambda$  (что также имеет место для рассматриваемой в работе модели Поттса).

## 3. Модель наблюдения

Выбор подходящей модели наблюдения является, пожалуй, самым важным фактором при применении байесовского подхода для обработки изображений. Моделью наблюдения является предположение о распределении вероятностей данных  $Y_i$  при фиксированной скрытой переменной:

$$P(y_i|x_i = \ell), \quad \ell = 1, \dots, L, \quad i \in V. \quad (6)$$

Следуя работам [3, 4], все данные (наблюдаемые реализации случайных величин  $Y_i, i \in V$ ) проецируются на гиперсферу единичного радиуса

$$\mathbb{S}^{p-1} = \{\mathbf{x} \in \mathbb{R}^p : \|\mathbf{x}\| = 1\}.$$

После такой нормировки можно использовать известные распределения статистики направленных значений (directional statistics), которые с успехом применяются для некоторых задач машинного обучения, таких, например, как кластеризация наблюдений [10].

В данной работе предполагается, что при фиксированном значении метки наблюдаемая случайная величина  $Y_i|x_i=\ell$ , соответствующая вокселю  $i \in V$ , имеет распределение фон Мизеса-Фишера с плотностью распределения

$$f(y_i; \mu_\ell, \kappa_\ell) = C_p(\kappa_\ell) \exp(\kappa_\ell \mu_\ell^T y_i), \quad y_i \in \mathbb{S}^{p-1}, \ell \in \Lambda, \quad (7)$$

где  $\mu_\ell \in \mathbb{S}^{p-1}$  – среднее направление,  $\kappa_\ell > 0$  – параметр концентрации. Данное распределение является аналогом нормального распределения на гиперсфере.

Нормировочная константа  $C_p(\kappa_\ell)$  в (7) определяется следующим выражением

$$C_p(\kappa_\ell) = \frac{\kappa_\ell^{p/2-1}}{(2\pi)^{p/2} I_{p/2-1}(\kappa_\ell)},$$

где  $I_\nu$  – модифицированная функция Бесселя первого рода.

#### 4. Оценка параметров

Качество полученной сегментации в рамках предлагаемой модели будет существенно зависеть от того, насколько хорошо значения параметров согласуются с наблюдаемыми данными. Поэтому особенно важной является задача оценки параметров.

Модель имеет следующие параметры:

- Параметр  $\beta$  в модели Поттса;
- Параметры модели наблюдения, т. е. параметры распределения фон Мизеса-Фишера:  $\Theta_\ell = \{\mu_\ell, \kappa_\ell\}$ ,  $\ell = 1, \dots, L$ .

В случае наличия обучающих размеченных данных можно получить оценку неизвестного параметра модели Поттса, например, с помощью метода максимального правдоподобия [7, 8].

С практической точки зрения гораздо более важной задачей является оценка параметров модели наблюдения. В случае наличия тренировочных размеченных данных искомые параметры оцениваются стандартным образом. Пусть  $\mathbf{y}^{(\ell)} = \{(y_1^{(\ell)}, \dots, y_N^{(\ell)}) \mid y_i^{(\ell)} \in \mathbb{S}^{p-1}\}$  – данные, отвечающие фиксированному классу  $\ell \in \Lambda$ , рассматриваемые как выборка из распределения фон Мизеса-Фишера. Тогда оценки параметров могут быть найдены с помощью метода максимального правдоподобия (см. подробности в [10]). Так, оценка среднего направления находится в явном виде:

$$\hat{\mu}_\ell = \frac{\sum_{i=1}^N y_i^{(\ell)}}{\left\| \sum_{i=1}^N y_i^{(\ell)} \right\|}, \quad (8)$$

а оценка параметра концентрации  $\kappa_\ell$  находится как корень следующего уравнения

$$\frac{I_{p/2}(\kappa_\ell)}{I_{p/2-1}(\kappa_\ell)} - \frac{\left\| \sum_{i=1}^N y_i^{(\ell)} \right\|}{N} = 0, \quad (9)$$

которое решается численно.

К сожалению, во многих прикладных задачах обработки изображений размеченные обучающие данные могут отсутствовать. Поэтому рядом исследователей были разработаны процедуры, позволяющие оценивать параметры непосредственно на основе обрабатываемых изображений. В этом смысле такого рода методы можно рассматривать как обучение без учителя. Основная идея заключается в построении итеративной процедуры, на каждой итерации которой сначала заново оценивается набор параметров, а затем находится оптимальная сегментация как решение задачи минимизации энергии (5). Таким образом, одновременно с

оцениваемыми параметрами находится и решение задачи. Проведем краткий обзор некоторых методов, которые были использованы в данной работе.

Одним из самых популярных является алгоритм HMRF-EM (Hidden Markov Random Field – Expectation maximization), предложенный в работе [5]. Данный метод был разработан для сегментации МРТ изображений головного мозга. В качестве модели бралось гауссовское распределение, при этом алгоритм не претерпит значительных изменений, если будет использоваться другое распределение, в том числе рассматриваемое в настоящей работе. Идея основана на EM-алгоритме [11], который позволяет находить оценки максимального правдоподобия при наличии скрытых (ненаблюдаемых) переменных. Структура алгоритма HMRF-EM выглядит следующим образом:

1.  $t = 0$ ; задается начальный набор параметров:  $\Theta^{(0)} = \{(\mu_\ell, \kappa_\ell), \ell \in \Lambda\}$ .
2. Находится оптимальная конфигурация  $\mathbf{x}^{(t)}$  как решение задачи (5) с текущим набором параметров  $\Theta^{(t)}$ .
3. Пусть  $N_i = \{j \in V : (i, j) \in \mathcal{E}\}$ . Для всех  $\ell \in \Lambda$  и  $i \in V$  рассчитываются следующие выражения:

$$P^{(t)}(\ell | y_i) = \frac{f(y_i; \mu_\ell^{(t)}, \kappa_\ell^{(t)}) P(\ell | x_j^{(t)}, j \in N_i)}{\sum_{\ell \in \Lambda} f(y_i; \mu_\ell^{(t)}, \kappa_\ell^{(t)}) P(\ell | x_j^{(t)}, j \in N_i)};$$

$$P(\ell | x_j^{(t)}, j \in N_i) = \exp \left( - \sum_{j \in N_i} V_{i,j}(x_i^{(t)}, x_j^{(t)}) \right).$$

4. Обновление параметров:

$$\mu_\ell^{(t+1)} = \frac{R_\ell}{\|R_\ell\|}, \quad R_\ell = \sum_{i \in V_\ell} P^{(t)}(\ell | y_i) y_i, \quad (10)$$

где  $V_\ell = \{j \in V : x_j = \ell\}$ .

$\kappa_\ell^{(t+1)}$  находится как решение уравнения:

$$\frac{I_{p/2}(\kappa_\ell)}{I_{p/2-1}(\kappa_\ell)} \sum_{i \in V_\ell} P(\ell | y_i) y_i = \|R_\ell\|; \quad (11)$$

$\Theta^{(t+1)} = \{(\mu_\ell^{(t+1)}, \kappa_\ell^{(t+1)}), \ell \in \Lambda\}$ .

5.  $t = t + 1$ ; если не достигнуто предельное число итераций, то возврат к шагу 2.

В отличие от оригинальной работы, оптимальная конфигурация на шаге 2 находится с помощью методов, основанных на разрезах графа [9].

В работах [3, 4] используется своего рода модификация предыдущего метода (HMRF-MSEM), которая состоит в том, что в EM-алгоритме математическое ожидание на шаге E аппроксимируется с помощью методов Монте-Карло по схеме марковских цепей (MCMC) [11]. Для этого генерируется реализации  $\{\mathbf{x}^1, \dots, \mathbf{x}^M\}$  из апостериорного распределения  $P(\mathbf{x} | \mathbf{y})$ . В этом случае шаг 3 будет отсутствовать, а на шаге 4 формулы (10), (11) заменятся соответственно на

$$\mu_\ell = \frac{R_\ell}{\|R_\ell\|}, \quad R_\ell = \sum_{m=1}^M \sum_{i \in V_\ell} x_i; \quad (12)$$

$$\frac{1}{M} \frac{I_{p/2}(\kappa_\ell)}{I_{p/2-1}(\kappa_\ell)} |V_\ell| = \frac{\|R_\ell\|}{M}. \quad (13)$$




Рис. 1. (a) Искомая сегментация (Ground truth), результаты сегментации: (b) HMRF-EM; (c) метод k-средних; (d) GrabCut; (e) HMRF-MCEM.




Рис. 2. (a) Наблюдаемое фМРТ-изображение (в поперечном сечении), результаты применения методов: (b) HMRF-MCEM (c) GrabCut (d) HMRF-EM

Наконец, третий из рассмотренных методов построен на той же самой процедуре, что используется в известном алгоритме GrabCut [6] для бинарной сегментации RGB изображений. Итеративная процедура состоит в том, что стартуя с некоторой начальной сегментации, сначала по данным  $V_\ell = \{j \in V : x_j = \ell\}$  с помощью формул (8), (9) оцениваются параметры  $(\mu_\ell, \kappa_\ell)$  для каждого класса  $\ell \in \Lambda$ , а затем находится MAP-оценка (5).

## 5. Эксперименты

В ходе работы были проведены эксперименты по сегментации синтетических данных. В начале генерируются изображения из априорного распределения (MRF с прямоугольной решеткой  $300 \times 300$  и стандартной системой соседства первого порядка) с помощью схемы Гиббса (Gibbs sampling). При генерации были использованы следующие значения параметров:  $L = 3$ ;  $\beta = 2$ . Эти изображения соответствуют искомой сегментации (Ground truth). Затем для каждого пикселя генерируется вектор наблюдений размерности  $p = 10$  с распределением фон Мизеса-Фишера. Таким образом, размерность сгенерированного наблюдаемого изображения  $300 \times 300 \times 10$ . После этого данные изображения подавались на вход алгоритмам с заданным числом классов сегментации  $L = 3$ . Результатом работы алгоритмов является сегментированное изображение размерности  $300 \times 300$ , которое затем сравнивается с Ground truth. Для того чтобы оценить качество полученной сегментации, рассчитывался так называемый простой коэффициент сходства  $J_1$ , равный отношению числа совпавших пикселей полученной сегментации к общему числу пикселей, а также обобщенный коэффи-

циент Жаккара для многоклассовой сегментации [12]:

$$J_2 = \frac{\sum_{l \in \Lambda} TP_l}{\sum_{l \in \Lambda} TP_l + FN_l + FP_l}, \quad (14)$$

где  $TP_l$  – количество правильно сегментированных пикселей класса  $l$ ,  $FN_l$  – количество пикселей класса  $l$  ошибочно отнесенных к другому классу,  $FP_l$  – количество пикселей ошибочно отнесенных к классу  $l$ .

Полученные сегментированные изображения представлены на рис. 1, где разные цвета соответствуют разным классам сегментации. Всего было проведено 100 идентичных экспериментов с синтетическими данными. Средние значения показателей представлены в таблице 1.

Стоит отметить, что, как показали эксперименты, результаты существенно зависят от начальных значений параметров, при произвольном выборе которых количественные показатели могут быть значительно ниже тех, что представлены в таблице 1. Начальные параметры могут быть оценены на основе начальной сегментации, найденной с помощью альтернативных методов, например алгоритма k-средних. По мнению авторов, можно с осторожностью утверждать, что рассмотренные методы, основанные на байесовском подходе с априорным распределением в виде марковских случайных полей, могут потенциально улучшать работу некоторых стандартных алгоритмов сегментации.

Метод	$J_1$	$J_2$
HMRF-MCEM	0.9923	0.9847
HMRF-EM	0.9910	0.9822
GrabCut	0.9605	0.9241
K-Means	0.9493	0.9035

Таблица 1. Сравнение методов сегментации

Также был проведен эксперимент с реальными данными фМРТ изображений из публично доступного набора репозитория NYU test–retest (TRT) [13, 14]. Данные представлены в виде четырехмерной матрицы размером  $64 \times 64 \times 39 \times 197$ , где первые три значения соответствуют пространственным координатам, а последнее – числу проведенных измерений (параметр  $p$ ). Целью эксперимента было показать, что результат метода HMRF-МСЕМ незначительно отличается от результатов двух других методов (HMRF-EM и GrabCut), которые являются более быстрыми. В ходе эксперимента была произведена сегментация изображения на два класса. Одно из поперечных сечений исходного изображения и соответствующие результаты сегментации представлены на рис. 2. Результаты оказались близкими, что дает основания полагать, что вместо вычислительно затратного алгоритма HMRF-МСЕМ, который был использован авторами для выделения зон функциональной активности головного мозга на основе фМРТ изображений после некоторой предварительной предобработки [3, 4], потенциально можно использовать и два других алгоритма.

## 6. Заключение

В работе исследуется задача сегментации многомерных фМРТ изображений на основе марковских случайных полей и моделей наблюдения специального вида. Проведен сравнительный анализ некоторых известных в литературе методов сегментации многомерных изображений, не предполагающих предварительное обучение на размеченных данных. В дальнейшем планируется провести большее количество экспериментов на реальных фМРТ изображениях. В качестве возможного будущего направления исследований предполагается провести эксперименты с иными моделями наблюдения, основанными на других распределениях статистики направленных значений.

## 7. Благодарности

Финансовое обеспечение исследований осуществлялось из средств федерального бюджета на выполнение государственного задания КарНЦ РАН (Институт прикладных математических исследований КарНЦ РАН) и при финансовой поддержке РФФИ (проекты 18-07-00187, 18-07-00147).

## 8. Литература

- [1] A. Eklund, T. E. Nichols, and H. Knutsson. Cluster failure: Why fmri inferences for spatial extent have inflated false-positive rates. *Proceedings of the National Academy of Sciences*, 113(28):7900–7905, 2016.
- [2] X. Descombes, F. Kruggel, and D. Y. Von Cramon. Spatio-temporal fmri analysis using markov random fields. *IEEE Transactions on Medical Imaging*, 17(6):1028–1039, Dec 1998.

- [3] W. Liu, S. P. Awate, J. Anderson, and P. Thomas Fletcher. A functional networks estimation method of resting-state fmri using a hierarchical markov random field. *NeuroImage*, 100:520–534, 2014.
- [4] W. Liu, S. P. Awate, J. Anderson, D. Yurgelun-Todd, and P. Thomas Fletcher. Monte carlo expectation maximization with hidden markov models to detect functional networks in resting-state fmri. In *Machine Learning in Medical Imaging*, pages 59–66, 2011.
- [5] Y. Zhang, M. Brady, and S. Smith. Segmentation of brain mr images through a hidden markov random field model and the expectation-maximization algorithm. *IEEE Transactions on Medical Imaging*, 20(1):45–57, 2001.
- [6] C. Rother, V. Kolmogorov, and A. Blake. Grabcut – interactive foreground extraction using iterated graph cuts. *ACM Transactions on Graphics (SIGGRAPH)*, 23(3):309–314, 2004.
- [7] P. Perez. Markov random fields and images. *CWI Quarterly*, pages 413–437, 1998.
- [8] M. A. Hurn, O. K. Husby, and H. Rue. A tutorial on image analysis. In *Spatial Statistics and Computational Methods*, pages 87–141. Springer New York, 2003.
- [9] Y. Boykov, O. Veksler, and R. Zabih. Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(11):1222–1239, Nov 2001.
- [10] A. Banerjee, I. S. Dhillon, J. Ghosh, and S. Sra. Clustering on the unit hypersphere using von mises-fisher distributions. *J. Mach. Learn. Res.*, 6:1345–1382, 2005.
- [11] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag, Berlin, Heidelberg, 2006.
- [12] W. R. Crum, O. Camara, and D. L. G. Hill. Generalized overlap measures for evaluation and validation in medical image analysis. *IEEE Transactions on Medical Imaging*, 25(11):1451–1461, Nov 2006.
- [13] X. Zuo, C. Kelly, J. S. Adelstein, D. F. Klein, F. X. Castellanos, and M. P. Milham. Reliable intrinsic connectivity networks: Test–retest evaluation using ica and dual regression approach. *NeuroImage*, 49(3):2163 – 2177, 2010.
- [14] NITRC. Nyu csc testretest dataset was obtained from [www.nitrc.org](http://www.nitrc.org), 2009 (accessed August 26 2019).

## Об авторах

Черняев Сергей Дмитриевич, магистрант института математики и информационных технологий Петрозаводского государственного университета. E-mail: schernyae@gmail.com.

Лукашенко Олег Викторович, к.ф.-м.н., научный сотрудник института прикладных математических исследований Карельского научного центра РАН; доцент Петрозаводского государственного университета. E-mail: lukashenko-oleg@mail.ru.