

Метод декомпозиции биологических объектов на МРТ изображениях при схожем фоне*

В. Н. Гридин, М. И. Труфанов, Н. Н. Яхно, В. Е. Синицын

Центр информационных технологий в проектировании РАН, Одинцово, Россия

Аннотация. Представлены результаты разработки метода для распознавания и измерения объектов на МРТ изображениях головного мозга, основанного на введении математического описания области перехода между биологическими объектами и последующей декомпозиции общего изображения головного мозга на отдельные биологические объекты. Отличием разработанного подхода является применение нейронных сетей лишь для упрощения поиска ключевых особенностей заданного биологического объекта, тогда как основная часть метода реализована в виде процедур вычисления признаков переходов между биологическими структурами посредством введения математической функции и последующей фильтрации обнаруженных ложных переходов.

Ключевые слова: магнитно-резонансная томография, анализ изображения, распознавание, гиппокамп, фильтрация изображения.

DOI 10.14357/20718632240204

EDN MQQEAA

Введение

Представленные исследования посвящены вопросу построения метода сегментации биологических тканей при анализе магнитно-резонансных томографических (МРТ) изображений в условиях, когда искомый объект по своим свойствам близок к расположенным вблизи него другим биологическим тканям. В качестве примера такого сложного объекта, рассматриваемого в данной работе, выбран гиппокамп на магнитно-резонансных изображениях головного мозга, который вследствие своего относительно малого размера, криволинейной формы и схожести с расположенными вблизи него тканями действительно является сложным для точной локализации на магнитно-резонансных изображениях, что подтверждается множеством публикаций,

ссылки на которые приведены ниже. В качестве входных данных рассматривается серия двумерных изображений оптических срезов в градациях оттенков серого, полученная магнитно-резонансным томографом в сагittalной проекции. Возможны и другие проекции – аксиальная или коронарная – но на принцип обработки данных разработанным методом это не влияет.

Предлагаемый метод для сегментации объектов на МРТ-изображениях головного мозга, базируется на вычислении свойств анализируемой области с последующим анализом выделенных объектов при помощи нейронных сетей и математического описания области перехода между биологическими объектами.

Преимуществом разработанного подхода является применение нейронных сетей лишь в начальной части процедуры распознавания и

* Исследование выполнено в рамках темы № FFNR-2024-0003.

упрощения поиска ключевых особенностей заданного биологического объекта, тогда как основная часть реализована в виде процедур вычисления признаков переходов между биологическими структурами и последующей фильтрацией ложных обнаруженных переходов путем анализа двумерных оптических срезов МРТ с последующим построением объемной модели анализируемой области.

Обзор известных методов сегментации биологических структур на МРТ и уточнение задачи исследований

Сегментация изображений биологических объектов по МРТ изображениям является актуальной для различных сфер применения в медицине при анализе состояния пациентов и здоровых людей.

Базируясь на обзоре методов сегментации и выделения искомых структур головного мозга, анализе методов обработки МРТ-изображений применительно к проблематике диагностики болезни Альцгеймера и когнитивных нарушений [1, 2, 3] можно сделать следующие выводы, определяющие постановку и цели исследований, представленных в данной работе. 1. Значительный объем публикаций, направленных на описание математических методов обработки изображения МРТ головного мозга ориентирован на выявление патологических образований, преимущественно опухолей различных видов [4]. При этом, как правило, в существующих решениях предполагается, что основные структуры мозга соответствуют нормальному состоянию, не подверженному или мало подверженному когнитивным нарушениям. Такое предположение – об относительно нормальных, не редуцированных вследствие когнитивных нарушений структур мозга – накладывает ограничения на применимость подходов применительно к случаям когнитивных нарушений и иным патологическим процессам. 2. Существующие методы сегментации как процесса разделения пикселей или воксельей на отдельные биологические анатомические структуры внутри одного оптического среза изображения или серии нескольких изоб-

ражений в объеме МРТ головного мозга в основном базируются также на предположении об относительно здоровом состоянии мозга и, как следствие, возможности применения так называемых медицинских атласов, содержащих априорно-обобщенную информацию о расположении и свойствах биологических структур, либо содержащих обобщенную информацию о наличии выявляемых инструментальными методами различий при поиске патологических образований [5]. 3. Применение известных подходов для сегментации сложных по форме объектов головного мозга, таких как, например, гиппокамп, в условиях деградации его объема и изменения формы вследствие различных нарушений существенно осложнено общими методами сегментации и требует применения отдельных подходов, ориентированных на обработку изображений гиппокампа или иных сложных для обработки анатомических структур головного мозга [6].

Вопросам сегментации МРТ-изображений головного мозга, под которой понимается разделение фрагментов МРТ-изображений на отдельные участки, принадлежащие одному биологическому объекту, также посвящен ряд работ [7-10]. В основной массе работ построение сегментирующих процедур реализовано при помощи обучения и последующего применения искусственных нейронных сетей. Такой подход, безусловно, реализуем, когда есть генеральная выборка для обучения нейронной сети и когда сегментируемые объекты не подвержены сильным изменениям, например, в результате патологических процессов. При этом, подобные подходы на основе искусственных нейронных сетей характеризуются и другим недостатком – снижением точности локализации границ объектов в случае их сложной структуры или схожести структуры биологического объекта с прилегающими тканями. Сходные результаты к декомпозиции биологических объектов по МРТ представлены в исследованиях [9], выявивших необходимость использования первичной обработки визуальных данных перед их подачей в искусственные нейронные сети. Другой задачей, актуальность которой также подтверждена различными исследователями [10], является анализ данных в

объеме пространства посредством формирования обособленных областей внутри общей структуры МРТ-данных, что обеспечивает более достоверное исключение ложных и помеховых структур.

Также известен большой спектр подходов к обнаружению и выделению гиппокампа как одной из наиболее сложных с точки зрения обработки изображений анатомических структур вследствие ее криволинейной формы, малого размера и схожести по структуре с прилегающими тканями [11]. В данном направлении в основной массе также применяются методы машинного обучения. Предлагаются решения, базирующиеся на формировании обучающей и валидационной выборок с использование изображений МРТ головного мозга здоровых людей и пациентов с редуцированными в объеме гиппокампами вследствие различных когнитивных нарушений и иных патологических процессов. Приводятся данные о недостатках подобных решений, несмотря на их работоспособность, как со здоровыми людьми, так и с пациентами с измененной формой и редуцированным объемом гиппокампа. Основными недостатками, по мнению авторов публикаций [12], являются высокая вычислительная сложность предложенных решений, требования к разрешающей способности приборов, на которых получены МРТ изображения, к относительно большому объему обучающей выборки. При этом, по мнению других авторов, отраженного в публикациях и, базируясь на результатах исследований авторов данной публикации, результативным решением в части детекции гиппокампа как примера одной из наиболее сложной анатомической структуры является совмещение подходов, основанных и на предварительной обработке изображений классическими методами обработки изображений, и на методах глубокого обучения с использованием нейронных сетей [13]. Это позволяет достичь и повышения точности локализации краев гиппокампа вследствие использования множества свойств его изображения, и снизить вычислительную ресурсоемкость вследствие обработки меньшего участка изображения. Также новизной предложенного подхода является введение функции фильтрации ложно найденных частей

гиппокампа или иного анализируемого объекта на МРТ путем анализа его объемного представления.

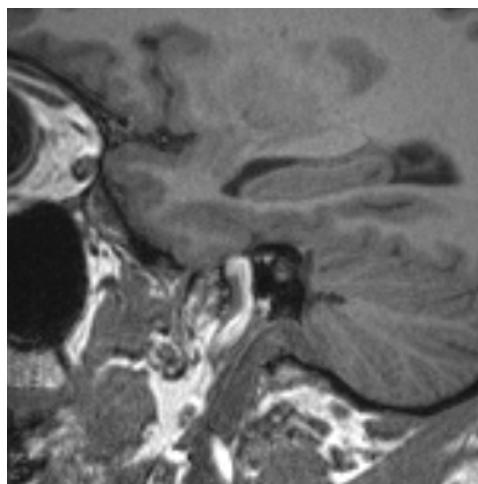
Ранее предложен метод для нахождения краев биологических объектов на медицинских изображениях, базирующийся на введении элементарных математических функций, аппроксимирующих поведение кривой яркости в области предполагаемой границы между объектами и формирующий вероятностное поле расположения границ объектов [14]. Суть метода заключается в построении вероятностного двумерного дискретного поля с размерностью, совпадающей с размерностью исходного двумерного изображения, нормированного в диапазоне от нуля до единицы, на котором единичные значения соответствуют предполагаемому элементу контура, определяющему различие между биологическим объектами, тогда как близость к нулю значений соответствует отсутствию различий в текущей анализируемой области изображения. Вариант результата построения такого вероятностного дискретного поля представлен на Рис. 1.

Недостатком решения [14] является лишь формирование вероятностного поля без последующей реализации сегментации на биологические объекты.

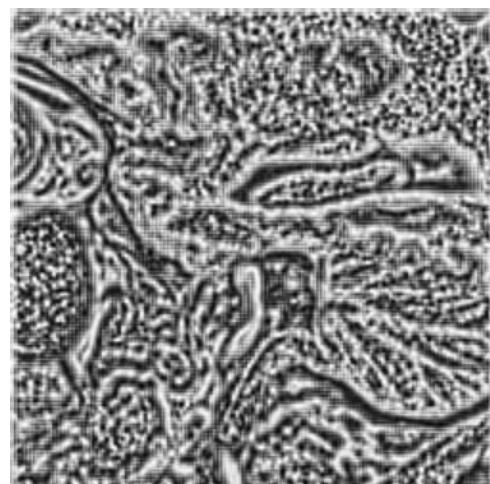
Разработанный и рассматриваемый в данной публикации метод базируется на оценке формы анализируемого объекта в пространстве МРТ объемного изображения. При этом одновременно используются и нейронные сети для первичной классификации признаков анализируемого объекта, и математические методы вычисления свойств перепада яркости, что в результате позволяет повысить точность локализации края анализируемого биологического объекта и более точно выполнить его декомпозицию среди других расположенных рядом тканей.

Описание разработанного метода

Рассмотрим предлагаемый метод определения объектов на МРТ-изображениях на примере анализа и выделения гиппокампа на МРТ головного мозга. Сущность метода заключается в выполнении следующих действий (Рис. 2).



а)



б)

Рис. 1. Результаты обработки части изображения МРТ головного мозга

а) исходное изображение, б) обработанное изображение с вероятностными краями биологических тканей

Первоначально выполняется ввод изображений. При необходимости осуществляются геометрические преобразования данных в сагittalную проекцию (блок 1 алгоритма на Рис. 2).

Изображения, выходящие из МРТ-томографа, как правило, уже являются пригодными к использованию, однако, в случае необходимости, они могут быть приведены к нормализованной яркости и контрастности (Рис. 2, блок 2).

Следующей операцией является операция выделения краев переходов между локальными структурами (Рис. 2, блок 3). На Рис. 1, (а) представлено входное изображение - область, содержащая гиппокамп и прилегающие к нему смежные биологические структуры, на Рис. 1, (б) – обработанное изображение.

Особенность обработанного изображения на Рис. 1, (б) состоит в том, что из-за математических особенностей применяемой функции для описания границ биологических объектов и относительно низкой разрешающей способности МРТ полученное изображение содержит и реально присутствующие области перехода между биологическими структурами, и шум. Удалить шум стандартными математическими методами (например, медианной фильтрацией, спектральными методами и т.д.) на подобном

изображении не представляется возможным ввиду потенциальной потери информации о реально присутствующих границах объектов. Поэтому для сегментации и декомпозиции изображения на реальные биологические объекты в разработанном методе введены последующие процедуры обработки.

После выделения переходов локальных структур с целью сохранения информации о внутренних особенностях объекта выполняется объединение исходного изображения и изображения, на котором выделены переходы, путем их суммирования с заданными весовыми коэффициентами. Также предполагается согласно разработанному методу раздельный анализ исходного, и полученного в результате обработки изображений.

Следующей операцией является блок 4, направленный на вычисление так называемых энергетических свойств локальных участков изображения в окрестности анализируемого биологического объекта на основе метода Лавса [15].

Для этого строятся матрицы, определяющие ядра свертки энергетических функций. После формирования матриц преобразованные изображения, полученные на основе свертки с ядрами Лавса, и исходные изображения подаются для обучения нейронных сетей.



Рис. 2. Алгоритм реализации метода выделения объектов на МРТ изображениях

Согласно представленному в методе Лавса математическому подходу вводятся векторы размерностью в пять элементов, из которых затем путем транспонирования и попарного перемножения формируется девять матриц размерностью 5x5. Полученные девять матриц

и являются ядрами, применяемыми для двумерной свертки изображений.

Формируют следующие векторы L, E, S, R:
 $L = \langle 1, 4, 6, 4, 1 \rangle$,
 $E = \langle -1, -2, 0, 2, 1 \rangle$,
 $S = \langle -1, 0, 2, 0, -1 \rangle$,
 $R = \langle 1, -4, 6, -4, 1 \rangle$.

После перемножения формируют результатирующие матрицы:

$$E^T \cdot R = \begin{pmatrix} -1 & 4 & -6 & 4 & -1 \\ -2 & 8 & -12 & 8 & -2 \\ 0 & 0 & 0 & 0 & 0 \\ 2 & -8 & 12 & -8 & 2 \\ 1 & -4 & 6 & -4 & 1 \end{pmatrix} \quad (1),$$

$$S^T \cdot S = \begin{pmatrix} 1 & 0 & -2 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 \\ -2 & 0 & 4 & 0 & -2 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & -2 & 0 & 1 \end{pmatrix} \quad (2),$$

$$R^T \cdot R = \begin{pmatrix} 1 & -4 & 6 & -4 & 1 \\ -4 & 16 & -24 & 16 & -4 \\ 6 & -24 & 36 & -24 & 6 \\ -4 & 16 & -24 & 16 & -4 \\ 1 & -4 & 6 & -4 & 1 \end{pmatrix} \quad (3),$$

$$E^T \cdot L = \begin{pmatrix} -1 & -4 & -6 & -4 & -1 \\ -2 & -8 & -12 & -8 & -2 \\ 0 & 0 & 0 & 0 & 0 \\ 2 & 8 & 12 & 8 & 2 \\ 1 & 4 & 6 & 4 & 1 \end{pmatrix} \quad (4),$$

$$S^T \cdot E = \begin{pmatrix} 1 & 2 & 0 & -2 & -1 \\ 0 & 0 & 0 & 0 & 0 \\ -2 & -4 & 0 & 4 & 2 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 2 & 0 & -2 & -1 \end{pmatrix} \quad (5),$$

$$R^T \cdot L = \begin{pmatrix} 1 & 4 & 6 & 4 & 1 \\ -4 & -16 & -24 & -16 & -4 \\ 6 & 24 & 36 & 24 & 6 \\ -4 & -16 & -24 & -16 & -4 \\ 1 & 4 & 6 & 4 & 1 \end{pmatrix} \quad (6),$$

$$S^T \cdot L = \begin{pmatrix} -1 & -4 & -6 & -4 & -1 \\ 0 & 0 & 0 & 0 & 0 \\ 2 & 8 & 12 & 8 & 2 \\ 0 & 0 & 0 & 0 & 0 \\ -1 & -4 & -6 & -4 & -1 \end{pmatrix} \quad (7),$$

$$R^T \cdot E = \begin{pmatrix} -1 & -2 & 0 & 2 & 1 \\ 4 & 8 & 0 & -8 & -4 \\ -6 & -12 & 0 & 12 & 6 \\ 4 & 8 & 0 & -8 & -4 \\ -1 & -2 & 0 & 2 & 1 \end{pmatrix} \quad (8),$$

$$R^T \cdot S = \begin{pmatrix} -1 & 0 & 2 & 0 & -1 \\ 4 & 0 & -8 & 0 & 4 \\ -6 & 0 & 12 & 0 & -6 \\ 4 & 0 & -8 & 0 & 4 \\ -1 & 0 & 2 & 0 & -1 \end{pmatrix} \quad (9).$$

Результаты применения двумерной свертки для каждой из девяти матриц (1) - (9) представлены на Рис. 3 и 4, на Рис. 3 – представлены для всего изображения оптического среза МРТ головного мозга, а на Рис. 4 – для выделенной области, содержащей гиппокамп.

Далее выполняется обучение нейронной сети. В качестве архитектуры сети выбрана архитектура yolo версии 5 [16]. Обоснованность выбора данной архитектуры обусловлена высокой скоростью реализации вычислений при достаточной точности распознавания объектов. Для обучения формируется массив данных, извлеченных из МРТ здоровых людей и пациентов с различной степенью измененности формы гиппокампа вследствие наличия когнитивных нарушений. Также в набор данных для обучения введены области, определяющие биологические структуры вверху и внизу (рассматривается сагittalная проекция) относительно гиппокампа, а также область церебро-спинальной жидкости вблизи гиппокампа по направлению к затылочной части головы.

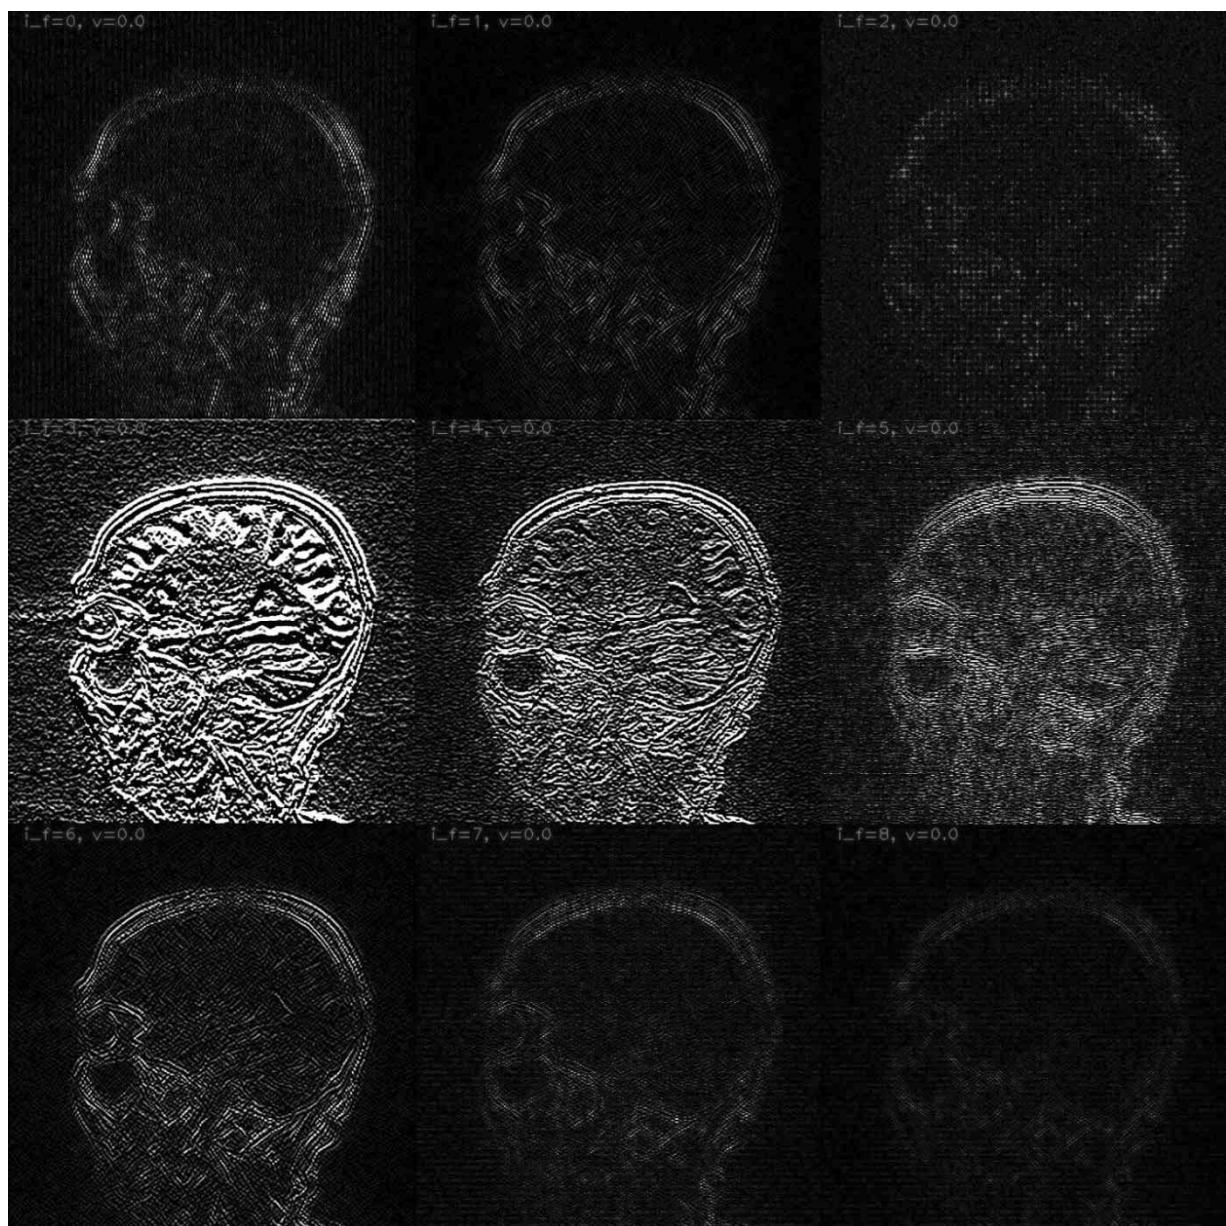


Рис. 3. Применение свертки оптического среза с матрицами Лавса с ядрами, заданными матрицами (1):-:(9)

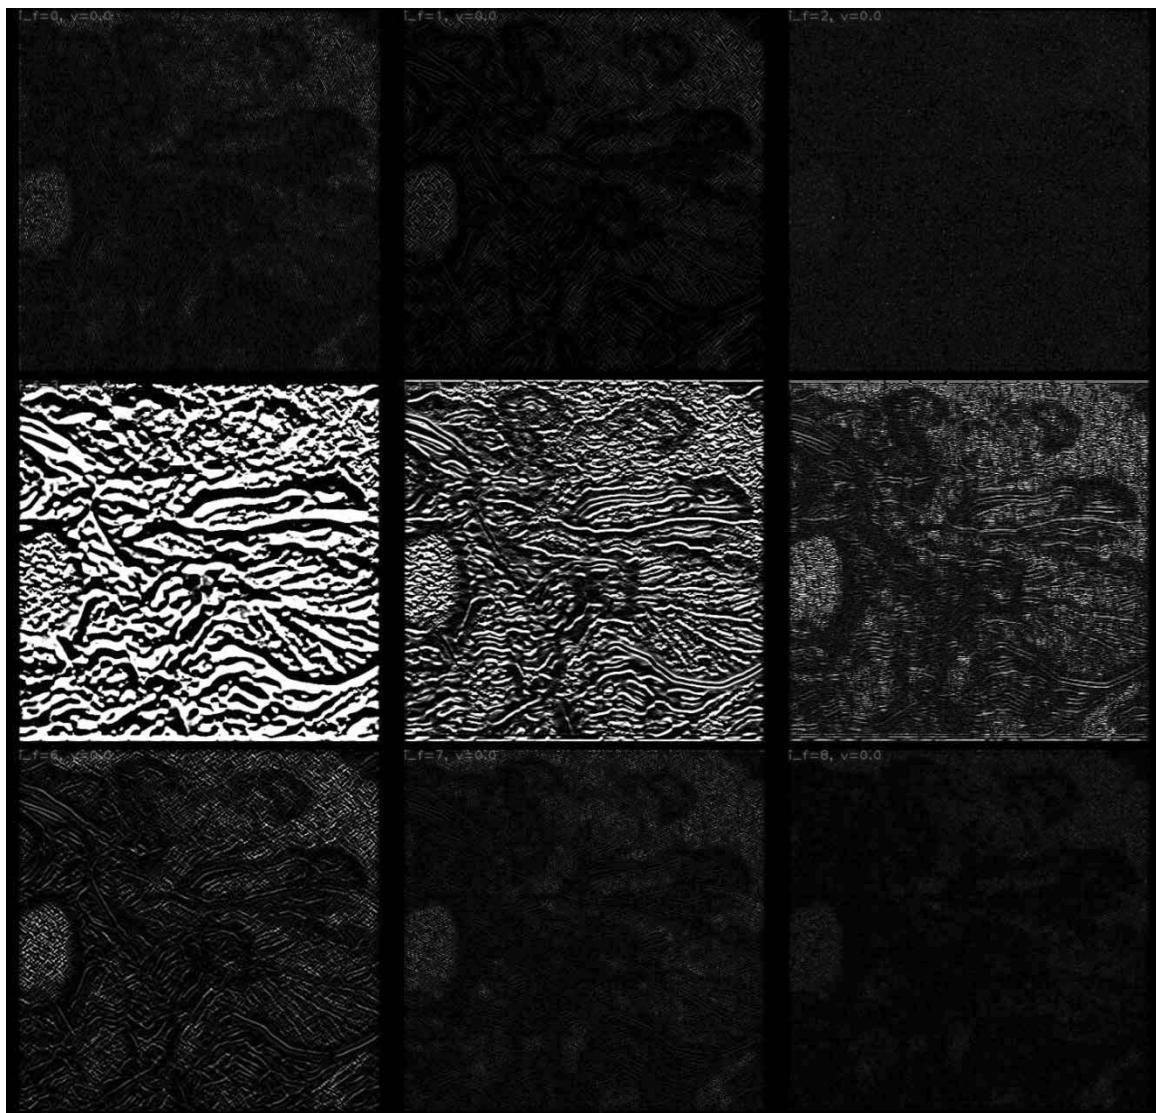


Рис. 4 Результат свертки изображения гиппокампа с матрицами Лавса с ядрами, заданными матрицами (1)-:(9)

Эталоны классов представлены на Рис. 5. При формировании разметки эталонных классов использовались изображения головного мозга размером 512 × 512 пикселей. Для изображений меньшего размера производилось увеличение изображения до необходимого размера с применением бикубической интерполяции при масштабировании. До разметки данных и формирования множества для обучения производился поворот каждого оптического среза на величину 30° с целью упрощения процедур разметки и последующего анализа данных. При работе нейросети выполняется аналогичный обратный поворот изображения.

Аугментация данных выполнялась путем введения дополнительного масштабирования при различных и неравных между собой величинах сжатия и растяжения изображения по осям абсцисс и ординат, а также путем поворота изображений в диапазоне ±25° на случайный угол (больший диапазон углов поворота при аугментации не требуется вследствие обработки данных в сагиттальной проекции и анатомических особенностей строения головного мозга).

После обучения выполняется распознавание на сериях оптических срезов заданных объектов, в данном случае гиппокампа, а также

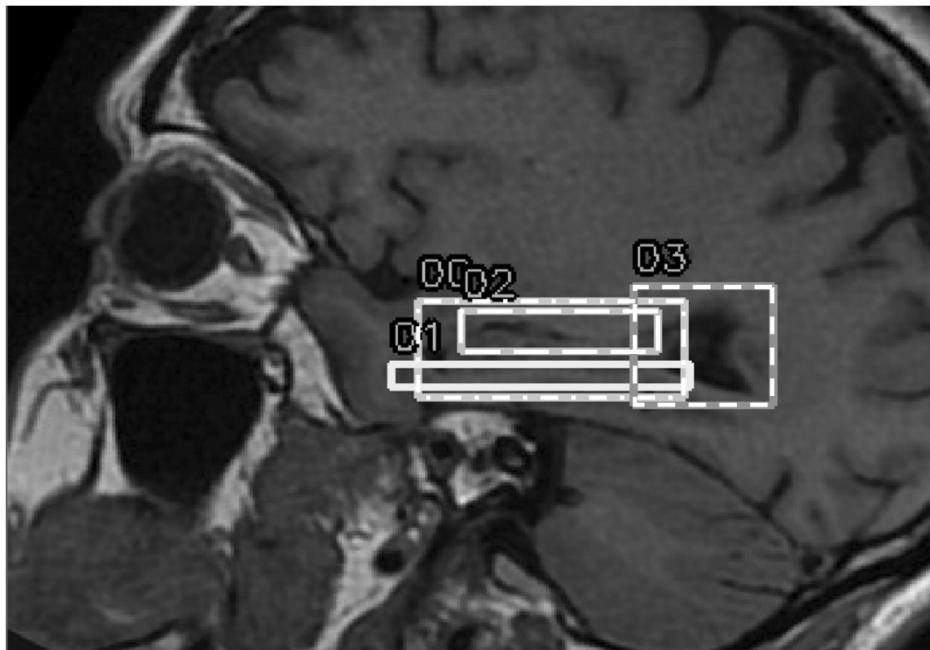


Рис. 5. Разметка данных при обучении нейронной сети: цифрами 00 показан гиппокамп, 01 – область границы над гиппокампом, 02 – область границы под гиппокампом, 03 – область цереброспинальной жидкости

структурных элементов, близко расположенных к гиппокампу, указанных на Рис. 5 классами 01 - 03.

Согласно разработанному методу высокая достоверность верного распознавания не предполагается в результате обучения на данном шаге обработки данных, т.к. определение точек, принадлежащих границам заданного объекта, выполняется на последующих этапах обработки. При определении заданных классов используются результаты распознавания с вероятностью более 50 %.

Далее выполняется обработка (Рис. 2, блок 6) всех оптических срезов, на которых может присутствовать гиппокамп [17]. В результате формируются прямоугольные области, описанные вокруг найденных объектов заданных классов, которые далее поступают на следующий шаг обработки.

Следующим шагом обработки является уточнение границ гиппокампа посредством построения кривых распределения яркости в области предполагаемой границы гиппокампа и анализа локальных экстремумов на сформированных кривых (Рис. 2, блок. 7).

Каждая кривая соответствует распределению яркости пикселей, расположенных на прямой, ортогональной к предполагаемой границе гиппокампа (Рис. 6). Для каждой кривой выполняется обнаружение локального минимума для верхней границы и локального максимума для нижней границы. При превышении по модулю соответствующих минимума и максимума заданным пороговым величинам текущая точка анализируется и остается в обработке, в противном случае исключается из дальнейших процедур обработки.

Следующим шагом обработки является соединение точек края гиппокампа от оптического среза к оптическому срезу (Рис. 2, блок 8). Так как форма анализируемого биологического объекта, а именно гиппокампа, является криволинейной формой, то от оптического среза к следующему оптическому срезу координаты границы гиппокампа будут меняться и, при этом, меняться незначительно. Для отслеживания точек края биологического объекта применяется метод на основе нахождения характерных точек и их сопоставления (Рис. 7) [18].

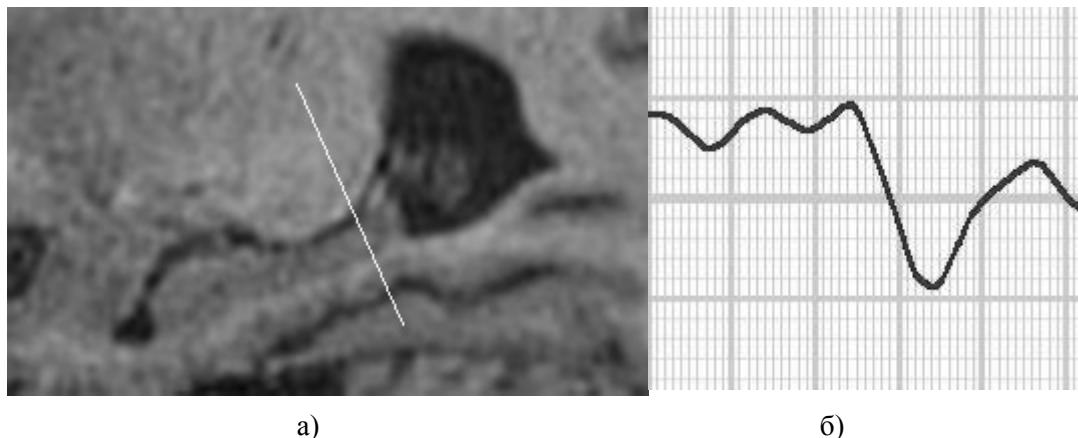


Рис. 6. Построение кривой (б) распределения яркости пикселей вдоль отрезка прямой, (а) ортогональной предполагаемой границе гиппокампа в заданной локальной точке

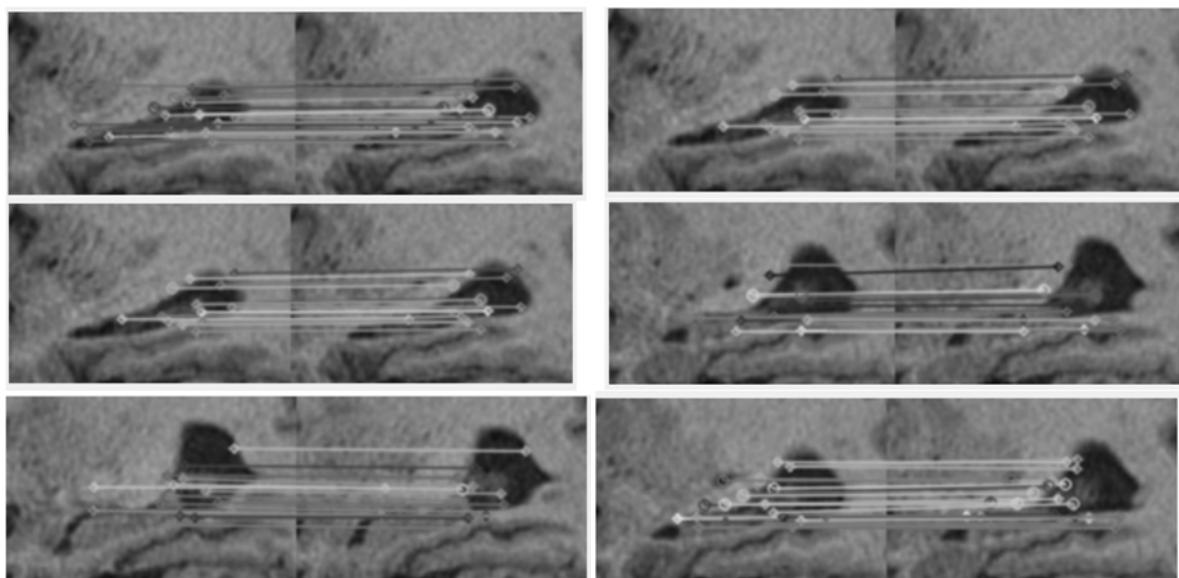


Рис. 7. Сопоставление точек в области гиппокампа от оптического среза к оптическому срезу

В результате формируется двумерное поле из множества кусочно-линейных кривых, соответствующих изменениям краев гиппокампа.

Затем сформированные области вероятных границ используется для построения объемной модели гиппокампа (Рис. 2, блоки 9, 10). При построении объемной модели гиппокампа выполняется двупроходный анализ оптических срезов. На первом проходе на основе анализа смежных оптических срезов производится первичное удаление ложных границ по принципу аналогичному медианному фильтру.

Результат формирования массива вероятных краев гиппокампа в виде кусочно-линейных

отрезков представлен на Рис. 8. Реализуется построение замкнутых линий, соответствующих области анализируемого объекта.

Затем строятся нормали к каждой точке предполагаемого края гиппокампа. Расчет прямой, которой принадлежит нормаль, выполняется по трем точкам, а знак (плюс или минус) направления нормали в случае неоднозначности принимается эквивалентным направлению от центра масс множества найденных точек краев гиппокампа к периферии оптического среза.

В результате к данному моменту обработки будут сформированы массив предполагаемых

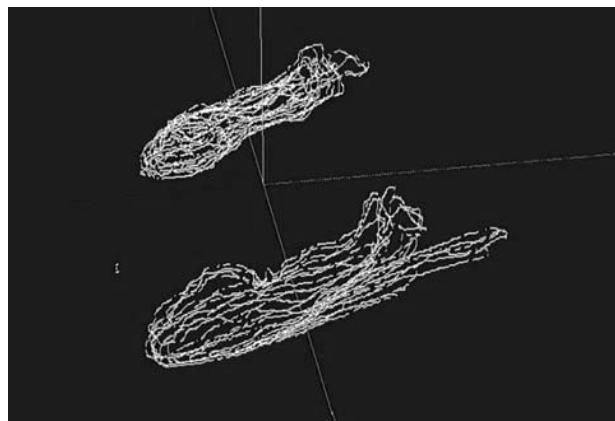


Рис. 8. Формирование массива вероятных границ гиппокампа

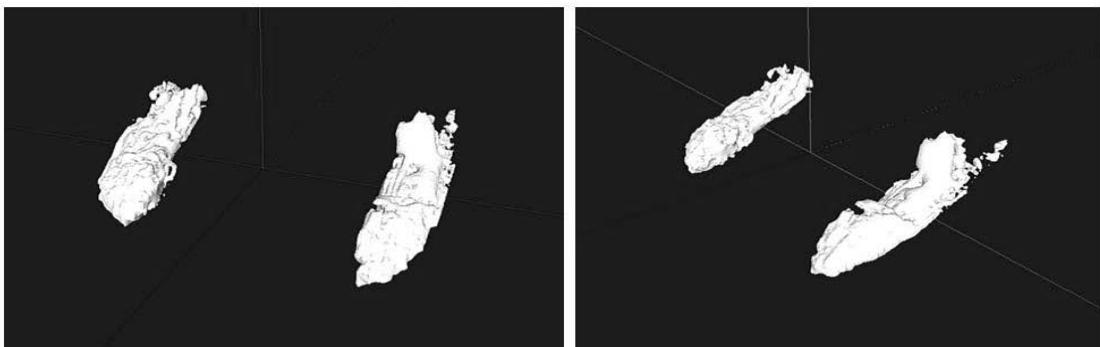


Рис. 9. Сформированная модель гиппокампа

точек, соответствующих границам гиппокампа в объеме головного мозга, а также нормали для каждой точки. По этим данным строится объемная модель гиппокампа (Рис. 9) [19, 20].

Далее производится удаление ложных частей анализируемого объекта исходя из его формы и размеров в пространстве. Удаляются ложные объемные объекты, которые характеризуются формой, не соответствующей строению, или имеющие малый объем, характерный для объектов, определяемых шумом или различными примесями в цереброспинальной жидкости. Рассмотрение автоматического процесса удаления ложных частей является предметом отдельной, следующей публикации. В данной работе ложные части удалены вручную исходя из критериев объема ложной части в случае ее объема меньше заданного порога, а также критериев ее геометрических свойств. В случаях неразрывности ложной части с основным объектом, эта ложная часть удаляется аналогично отдельно расположенной ложной части.

Для данного примера в качестве ложных частей приняты части, показанные прямоугольником на Рис. 10 и характеризуемые малым размером и местоположением, не соответствующих анатомической форме гиппокампа.

На следующей стадии обработки после получения объемной модели производится обратный переход к двумерным проекциям в случае таковой необходимости, и окончательное принятие решения о найденных краях биологических объектов и выполнении сегментации.

Для валидации разработанного метода были использованы результаты измерения объема гиппокампа на основе выборки МРТ, представленной в [21] и состоящий из 41 обследованного лица. Проводилось сравнение результатов измерения объема гиппокампов путем выделения гиппокампа, и оценки его объема с использованием разработанного подхода и программного продукта FMRIB Software Library. В качестве эталонной разметки ground truth для сравнения использована ручная разметка.

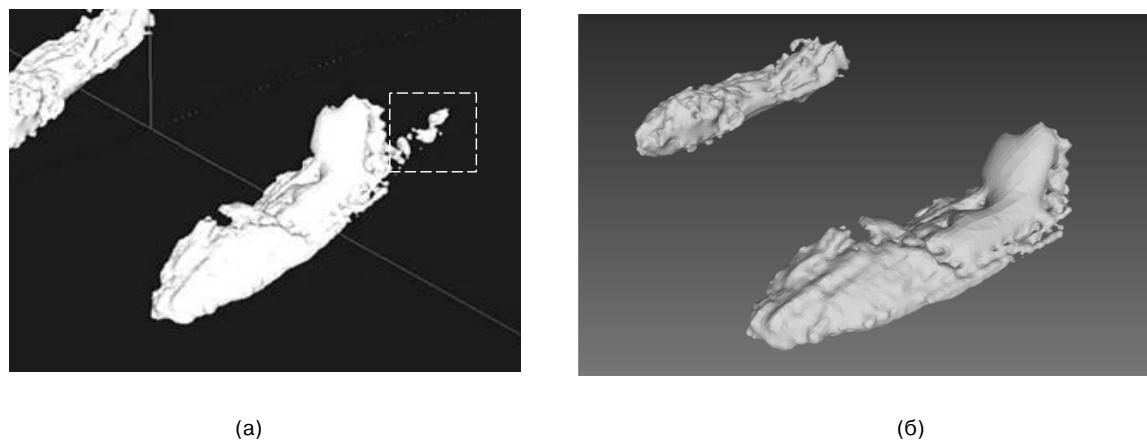


Рис. 10. Удаление ложных частей в сформированной объемной модели (а) (показаны пунктирным прямоугольником) и результирующая модель (б)

Сравнение показало, что использование предложенного метода позволяет повысить в среднем на 9% точность выделения области гиппокампа для пациентов с измененным относительно нормального состояния объемом гиппокампа, и в среднем на 4% для здоровых людей.

Выводы

В результате разработки метода локализации биологических структур на МРТ-изображениях головного мозга предложен подход, позволяющий с большей точностью по сравнению с аналогичными решениями выделять области на МРТ.

Отличием разработанного метода от известных является использование искусственных нейронных сетей лишь как вспомогательного средства первичного выделения краев объектов при реализации основных процедур обработки в виде формализованных математических процедур.

Другой значимой новизной является переход в процессе реализации метода к формированию объемной модели и фильтрация ложных и помеховых объектов по объемной модели с последующим обратным переходом к двумерным проекциям оптических срезов МРТ.

Литература

1. Гридин В.Н., Перепелов В.А., Панищев В.С., Труфанов М.И., Яхно Н.Н. Алгоритм вычисления параметров гиппокампа при диагностике болезни альцгеймера / Биомедицинская радиоэлектроника. 2019. Т. 22. № 7. С. 5-15.
2. Гридин В.Н., Труфанов М.И., Соловьев В.И., Панищев В.С., Синицын В.Е., Яхно Н.Н. Автоматический анализ количественных характеристик гиппокампа при магнитно-резонансной томографии головного мозга для диагностики возможной болезни альцгеймера (обзор литературы и результаты собственных исследований) / Радиология - практика. 2017. № 6 (66). С. 41-59.
3. Fawzi A, Achuthan A, Belaton B. Brain Image Segmentation in Recent Years: A Narrative Review. Brain Sciences. 2021; 11(8):1055. <https://doi.org/10.3390/brainsci11081055>.
4. Soltaninejad M, Yang G, Lambrou T, Allinson N, Jones TL, Barrick TR, Howe FA, Ye X. Supervised learning based multimodal MRI brain tumour segmentation using texture features from supervoxels. Comput Methods Programs Biomed. 2018 Apr; 157:69-84. doi: 10.1016/j.cmpb.2018.01.003.
5. Fedde van der Lijn a b, Tom den Heijer c d, Monique M.B. Breteler c, Wiro J. Niessen. Hippocampus segmentation in MR images using atlas registration, voxel classification, and graph cuts/ NeuroImage Volume 43, Issue 4, December 2008, Pages 708-720.
6. Benjamin Thyreau, Kazunori Sato, Hiroshi Fukuda, Yasuyuki Taki / Segmentation of the hippocampus by transferring algorithmic knowledge for large cohort processing // Medical Image Analysis, Volume 43, 2018, Pages 214-228.
7. Lin, D., Rajinikanth, V., Lin, H. (2021). Hybrid Image Processing-Based Examination of 2D Brain MRI Slices to Detect Brain Tumor/Stroke Section: A Study. In: Priya, E., Rajinikanth, V. Signal and Image Processing Techniques for the Development of Intelligent Healthcare Systems. Springer, Singapore. https://doi.org/10.1007/978-981-15-6141-2_2.
8. Hasnain Ali Shah, Faisal Saeed, Sangseok Yun, Jun-Hyun Park, Anand Paul, Jae-Mo Kang, "A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet", IEEE Access, vol.10, pp.65426-65438, 2022.
9. K. Tartarotti Nepomuceno Duarte, M. Andrade Nascimento Moura, P. Sergio Martins and M. A. Garcia de Carvalho, "Brain Extraction in Multiple T1-weighted Magnetic Reso-

- nance Imaging slices using Digital Image Processing techniques," in IEEE Latin America Transactions, vol. 20, no. 5, pp. 831-838, May 2022, doi: 10.1109/TLA.2022.9693568.
10. Automated Classification of Alzheimer's Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture, Y N Fu'adah, I Wijayanto, N K C Pratiwi, F F Taliningsih, S Rizal and M A Pramudito. Journal of Physics: Conference Series, Volume 1844, 2020 2nd International Conference on Science & Technology (2020 2nd ICOST) 28 November 2020, Yogyakarta, Indonesia.
 11. Yi, P., Jin, L., Xu, T., Wei, L. and Rui, G. (2021), Hippocampal Segmentation in Brain MRI Images Using Machine Learning Methods: A Survey. Chinese J. Electron., 30: 793-814.
 12. MRI image synthesis with dual discriminator adversarial learning and difficulty-aware attention mechanism for hippocampal subfields segmentation. Baoqiang Ma, Yan Zhao, Yujing Yang et al / Computerized Medical Imaging and Graphics, Volume 86, December 2020, 101800.
 13. Zhenxi Zhang, Jie Li, Chunna Tian, Zhusi Zhong, Zhicheng Jiao, Xinbo Gao / Quality-driven deep active learning method for 3D brain MRI segmentation // Neurocomputing, Volume 446, 2021, Pages 106-117.
 14. Гридин В.Н., Газов А.И., Новиков И.А., Соловьевников В.И., Труфанов М.И. / Немасштабируемые функции в качестве моделей границы биологического объекта // Системы высокой доступности. 2021. Т. 17. № 4. С. 66-75.
 15. S. Dash, U. Jena, Multi-resolution Laws' Masks based texture classification. Journal of Applied Research and Technology, 2019, 15(6).
<https://doi.org/10.1016/j.jart.2017.07.005>
 16. Bochkovskiy, A., Wang, C.-Y., & Mark Liao, H.-Y. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv. <https://arxiv.org/pdf/2004.10934.pdf>
 17. V.N. Gridin, M.I. Trufanov, V.I. Solodovnikov, V.S. Panishchev, V.E. Sinitsyn, N.N. Yakhno. Automatic analysis of the quantitative characteristics of the hippocampus in magnetic resonance imaging of the brain for the diagnosis of possible Alzheimer's disease (literature review and results of our own research) / Radiology - practice. No. 6 2017. S. 41-59.
 18. Chuan Luo, Wei Yang, Panling Huang, Jun Zhou. Overview of Image Matching Based on ORB Algorithm. IOP Conf. Series: Journal of Physics: Conf. Series 1237 (2019), doi:10.1088/1742-6596/1237/3/032020.
 19. Surface reconstruction from a sparse point cloud by enforcing visibility consistency and topology constraints Computer Vision and Image Understanding Volume 175, October 2018, Pages 52-71
<https://doi.org/10.1016/j.cviu.2018.09.007>.
 20. Detail Preserved Surface Reconstruction from Point Cloud Yang Zhou, Shuhan Shen and Zhanyi Hu Sensors 2019, 19, 1278; doi:10.3390/s19061278.
 21. Яхно Н.Н., Гридин В.Н., Перепелов В.А., Синицын В.Е., Коберская Н.Н., Смирнов Д.С., Соловьевников В.И., Труфанов М.И. / Объемные характеристики гиппокампов по данным мр-вolumетрии у пациентов с болезнью альzheimera // Российский электронный журнал лучевой диагностики. 2020. Т. 10. № 1. С. 50-58.

Гридин Владимир Николаевич. Центр информационных технологий в проектировании РАН, г. Одинцово, Россия. Научный руководитель. Доктор технических наук, профессор. Область научных интересов: системы автоматизированного проектирования. E-mail: info@ditc.ras.ru

Труфанов Максим Игоревич. Центр информационных технологий в проектировании РАН, г. Одинцово, Россия. Старший научный сотрудник, кандидат технических наук, доцент. Область научных интересов: информационные технологии, анализ и обработка данных. E-mail: info@ditc.ras.ru

Яхно Николай Николаевич. Центр информационных технологий в проектировании РАН, г. Одинцово, Россия. Главный научный сотрудник, доктор математических наук, академик. Область научных интересов: клиническая нейрофизиология, патология вегетативной нервной системы. E-mail: info@ditc.ras.ru

Синицын Валентин Евгеньевич. Центр информационных технологий в проектировании РАН, г. Одинцово, Россия. Главный научный сотрудник, доктор математических наук, профессор. Область научных интересов: лучевая диагностика болезней сердца и сосудов. E-mail: info@ditc.ras.ru

The Method of Decomposition of Biological Objects on MRI Images with a Similar Background

V. N. Gridin, M. I. Trufanov, N. N. Yakhno, V. E. Sinitsyn

Design Information Technologies Center Russian Academy of Sciences, Odintsovo, Moscow oblast, Russia

Abstract. The results of the development of a method for recognizing and measuring objects on MRI brain inventions based on the introduction of a mathematical description of the transition area between

biological objects and the subsequent decomposition of the general image of the brain into separate biological objects are presented. A distinctive feature of the developed approach is the use of neural networks only to simplify the search for key features of a given biological object, whereas the main part of the method is implemented in the form of procedures for calculating signs of transitions between biological structures by introducing a mathematical function and then filtering false detected transitions.

Keywords: magnetic-resonance imaging, image processing, recognition, hippocampus, image filtering.

DOI 10.14357/20718632240204 **EDN MQQEAA**

References

1. Gridin V.N., Perepelov V.A., Panishchev V.S., Truphanov M.I., Yakhno N.N. Algorithm for calculating hippocampal parameters in the diagnosis of alzheimer's disease / Biomedical radioelectronics. 2019. V. 22. N 7. P. 5-15.
2. Gridin V.N., Truphanov M.I., Solodovnikov V.I., Panishchev V.S., Sintsyn V.E., Yakhno N.N. Automatic analysis of quantitative characteristics of the hippocampus in magnetic resonance imaging of the brain for the diagnosis of possible alzheimer's disease (review of literature and results of own research) / Radiology-practices. 2017. N 6 (66). P. 41-59.
3. Fawzi A, Achuthan A, Belaton B. Brain Image Segmentation in Recent Years: A Narrative Review. *Brain Sciences*. 2021; 11(8):1055. <https://doi.org/10.3390/brainsci11081055>.
4. Soltaninejad M, Yang G, Lambrou T, Allinson N, Jones TL, Barrick TR, Howe FA, Ye X. Supervised learning based multimodal MRI brain tumour segmentation using texture features from supervoxels. *Comput Methods Programs Biomed.* 2018 Apr; 157:69-84. doi: 10.1016/j.cmpb.2018.01.003.
5. Fedde van der Lijn a b, Tom den Heijer c d, Monique M.B. Breteler c, Wiro J. Niessen. Hippocampus segmentation in MR images using atlas registration, voxel classification, and graph cuts/ *NeuroImage* Volume 43, Issue 4, December 2008, Pages 708-720.
6. Benjamin Thyreau, Kazunori Sato, Hiroshi Fukuda, Yasuyuki Taki / Segmentation of the hippocampus by transferring algorithmic knowledge for large cohort processing // *Medical Image Analysis*, Volume 43, 2018, Pages 214-228.
7. Lin, D., Rajinikanth, V., Lin, H. (2021). Hybrid Image Processing-Based Examination of 2D Brain MRI Slices to Detect Brain Tumor/Stroke Section: A Study. In: Priya, E., Rajinikanth, V. Signal and Image Processing Techniques for the Development of Intelligent Healthcare Systems. Springer, Singapore. https://doi.org/10.1007/978-981-15-6141-2_2.
8. Hasnain Ali Shah, Faisal Saeed, Sangseok Yun, Jun-Hyun Park, Anand Paul, Jae-Mo Kang, "A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet", IEEE Access, vol.10, pp.65426-65438, 2022.
9. K. Tartarotti Nepomuceno Duarte, M. Andrade Nascimento Moura, P. Sergio Martins and M. A. Garcia de Carvalho, "Brain Extraction in Multiple T1-weighted Magnetic Resonance Imaging slices using Digital Image Processing techniques," in IEEE Latin America Transactions, vol. 20, no. 5, pp. 831-838, May 2022, doi: 10.1109/TLA.2022.9693568.
10. Automated Classification of Alzheimer's Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture, Y N Fu'adah, I Wijayanto, N K C Pratiwi, F F Taliningsih, S Rizal and M A Pramudito. *Journal of Physics: Conference Series*, Volume 1844, 2020 2nd International Conference on Science & Technology (2020 2nd ICoST) 28 November 2020, Yogyakarta, Indonesia.
11. Yi, P., Jin, L., Xu, T., Wei, L. and Rui, G. (2021), Hippocampal Segmentation in Brain MRI Images Using Machine Learning Methods: A Survey. *Chinese J. Electron.*, 30: 793-814.
12. MRI image synthesis with dual discriminator adversarial learning and difficulty-aware attention mechanism for hippocampal subfields segmentation. Baoqiang Ma, Yan Zhao, Yujing Yang et al / *Computerized Medical Imaging and Graphics*, Volume 86, December 2020, 101800.
13. Zhenxi Zhang, Jie Li, Chunna Tian, Zhusi Zhong, Zhicheng Jiao, Xinbo Gao / Quality-driven deep active learning method for 3D brain MRI segmentation // *Neurocomputing*, Volume 446, 2021, Pages 106-117.
14. Gridin V.N., Gazov A.I., Novikov I.A., Solodovnikov V.I., Trufanov M.I. / Non-scalable functions as models of the boundary of a biological object // *High Availability Systems*. 2021. V. 17. N 4. P. 66-75.
15. 5. Dash, S., & Jena, U. Multi-resolution Laws' Masks based texture classification. *Journal of Applied Research and Technology*, 2019, 15(6). <https://doi.org/10.1016/j.jart.2017.07.005>
16. Bochkovskiy, A., Wang, C.-Y., & Mark Liao, H.-Y. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv. <https://arxiv.org/pdf/2004.10934.pdf>
17. V.N. Gridin, M.I. Trufanov, V.I. Solodovnikov, V.S. Panishchev, V.E. Sintsyn, N.N. Yakhno. Automatic analysis of the quantitative characteristics of the hippocampus in magnetic resonance imaging of the brain for the diagnosis of possible Alzheimer's disease (literature review and results of our own research) / Radiology - practice. No. 6 2017.S. 41-59.
18. Chuan Luo, Wei Yang, Panling Huang, Jun Zhou. Overview of Image Matching Based on ORB Algorithm. *IOP Conf. Series: Journal of Physics: Conf. Series* 1237 (2019), doi:10.1088/1742-6596/1237/3/032020.
19. Surface reconstruction from a sparse point cloud by enforcing visibility consistency and topology constraints *Computer Vision and Image Understanding* Volume 175, October 2018, Pages 52-71 <https://doi.org/10.1016/j.cviu.2018.09.007>.
20. Detail Preserved Surface Reconstruction from Point Cloud Yang Zhou, Shuhan Shen and Zhanyi Hu Sensors 2019, 19, 1278; doi:10.3390/s19061278.

21. Yakhno N.N., Gridin V.N., Perepelov V.A., Sinitsyn V.E.,
Koberskaya N.N., Smirnov D.S., Solodovnikov V.I. 1,

Trufanov M.I. / Hippocampal volume based on mri-volumetric analysis in alzheimer disease patients // Russian electronic journal of radiology. 2020. V. 10. N 1. P. 50-58.

Gridin Vladimir N. Design information technologies Center Russian Academy of Sciences, Russia, Odintsovo, St. of the Marshala Biryuzova of 7a, scientific director, Dr.Sci.Tech., professor. E-mail: info@ditc.ras.ru

Trufanov Maxim I. Design information technologies Center Russian Academy of Sciences, Russia, Odintsovo, St. of the Marshala Biryuzova of 7a, candidate of technical sciences, senior researcher, docent. E-mail: info@ditc.ras.ru

Yakhno Nikolay N. Design information technologies Center Russian Academy of Sciences, Russia, Odintsovo, St. of the Marshala Biryuzova of 7a, chief researcher, Doctor of Medical Sciences, academician. E-mail: info@ditc.ras.ru

Sinitsyn Valentin E. Design information technologies Center Russian Academy of Sciences, Russia, Odintsovo, St. of the Marshala Biryuzova of 7a, chief researcher, Doctor of Medical Sciences, professor. E-mail: info@ditc.ras.ru