В.П. Фраленко, М.В. Хачумов, М.В. Шустова

Инструментальные средства автоматического поиска и визуализации зон интереса в данных МРТ для поддержки принятия решений врачей-исследователей

Аннотация. В статье дано развернутое описание разработанных авторами методов первичной и глубокой обработки данных магнитно-резонансной томографии, направленных на обнаружение зон ишемического поражения в мозге крыс. В состав инструментов входят методы приведения МРТ-изображений различных образцов к нормализованному виду (размеры, форма, яркость). Другой набор средств связан с обнаружением аномалий по Т2- и ИКД-снимкам с помощью искусственных нейронных сетей и специальных метрик. Предполагается, что созданные алгоритмы и программы войдут в состав разрабатываемого исследовательского программного комплекса, ориентированного на поддержку принятия решений врачей-исследователей.

Ключевые слова: магнитно-резонансная томография, мозг, ишемическое поражение, распознавание, визуализация, метрика, сверточная нейронная сеть.

Введение

В статье отрабатываются инструментальные средства для автоматизированной обработки данных МРТ. Предполагается, что полученные методы и алгоритмы, а также имеющееся готовое программное обеспечение будут в комплексе использованы для поддержки принятия решений врачей-исследователей, занимающихся прижизненным наблюдением головного мозга животных (крыс). Разработанные алгоритмы и программы обеспечивают проведение расчетов, связанных с унификацией представления головного мозга различных особей с целью последующей оценки поврежденных областей; выполнение глубокой обработки и когнитивной визуализации, связанной с научной подсветкой областей интереса исследователя.

Необходимость автоматизации обработки МРТ-изображений обусловлена рядом причин: интенсивный поток поступающих данных (в результате каждого МРТ-исследования мозга отдельной крысы получают десятки изображений, требующих дальнейшей обработки); ограниченное количество экспертов; отсутствие программного обеспечения и необходимых качественных устройств для научной визуализации информации. Автоматизация затрагивает два аспекта исследований: предварительную и глубокую обработку потоков данных. Полученные МРТ-изображения отличаются неустойчивыми показателями яркости и контрастности, что требует их нормализации. Выделение зон интереса сопряжено со значительными трудностями, определяемыми неоднородностью информации по срезам МРТ, наличием только одного характерного признака

[1]Работа выполнена при финансовой поддержке проекта РФФИ №16-29-07116 «Информационно-аналитические модели и методы когнитивной визуализации процессов миграции и хоуминга трансплантированных мезенхимальных стволовых клеток для поддержки проведения научных исследований и разработки подходов к лечению заболеваний методами клеточной терапии».

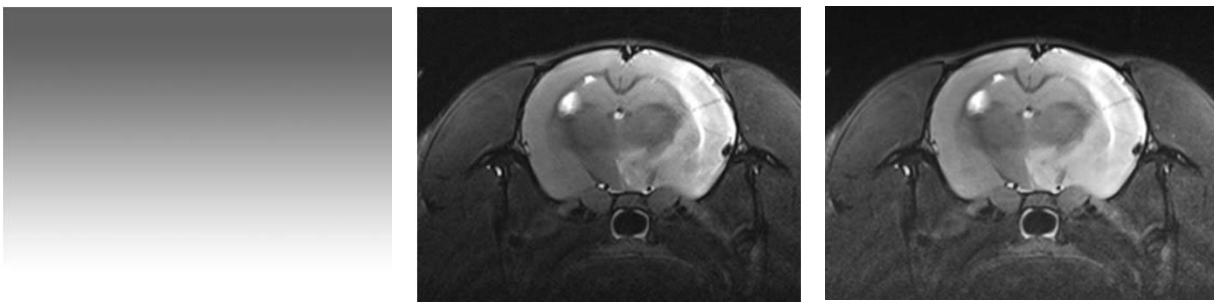

а) б) в)

Рис. 1. Пример выравнивания яркости

а - изображение-градиент; б - исходное изображение; в - обработанное изображение

– уровня сигнала. Это требует искусственного расширения признакового пространства, введения мощных инструментальных средств для отделения зон интереса от прочих областей мозга (сегментации). Известные в настоящее время средства автоматической сегментации мозга практически не обеспечивают требуемого экспертами качества [1-3]. В этой связи настоящая работа посвящена устранению имеющихся пробелов на основе средств искусственного интеллекта: искусственных нейронных сетей, методов выделения информативных текстурных признаков, специальных метрик и тематической визуализации.

Экспериментальная часть работы выполнялась на основе данных послойных МРТ-исследований головного мозга крыс. Применялся высокопольный томограф для малых животных ClinScan (Bruker BioSpin) с индукцией магнитного поля 7T под ингаляционным наркозом. Для поиска зон ишемического поражения были использованы T2-взвешенные изображения на поздних стадиях и диффузионно-взвешенные изображения в острой фазе ишемии.

1. Инструментальные средства предварительной обработки данных МРТ

1.1. Выравнивание яркости изображения методом смешения с градиентом

Важное место в исследованиях головного мозга занимают инструментальные средства предварительной обработки, позволяющие улучшить качество данных и изображений в целом или их отдельных фрагментов. Сюда входят алгоритмы управления яркостью, четкостью и контрастностью, подчеркивания границ и др. Используемый томограф ClinScan имеет некоторые конструктивные особенности, из-за которых изображения получаются неравномерно освещенными, что влечет за собой ухудшение качества последующей обработки. Отсюда возникает необходимость в нормализации градиента яркости. Данная задача решается авторами с помощью попиксельного наложения серо-белого изображения-градиента (Рис. 1,а) на исходное изображение (Рис. 1,б). Наложение выполняется по следующей формуле:

$$f(a,b)=\begin{cases}\dfrac{ab}{127,5}, & \text{если } a<127,5\\ 2a+2b-\dfrac{ab}{127,5}-255, & \text{иначе}\end{cases},$$

где a – значение яркости пикселя исходного изображения, b – значение яркости соответствующего пикселя изображения-градиента; значения яркости пикселей обоих изображений изменяются от 0 (черный цвет) до 255 (белый цвет).

Используемое изображение-градиент подобрано эмпирически исходя из имеющихся характерных для томографа изображений. Результат выравнивания яркости приведен на Рис. 1,в.

Метод был применен для последующего исследования T2-снимков и позволил добиться повышения качества сегментации.

1.2. Приведение МРТ-изображения мозга крысы к эталонному

При обработке МРТ-снимков головного мозга различных крыс, обладающих индивидуальными особенностями строения, возникает задача сопоставления (регистрации) целевых изображений с некоторым эталоном. Актуальность этой задачи

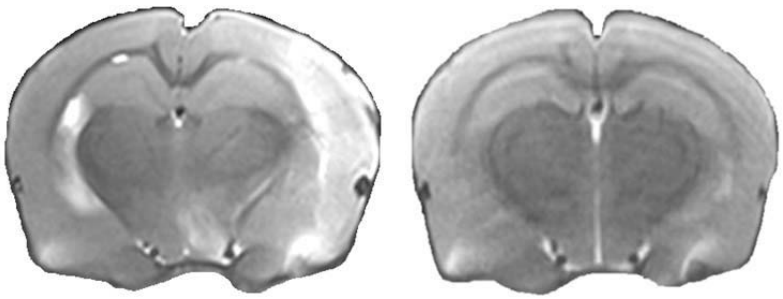

а) б)

Рис. 2. Эталонное (а) и обрабатываемое (б) изображения

для сегментирования мозга на анатомические области подчеркнута в работах [4, 5]. Разработанный в рамках настоящего исследования метод ориентирован на предварительно подготовленные снимки, когда мозг животного отделен от фона. Для этой цели имеется готовое программное обеспечение [1-3]. На Рис. 2 показан пример эталонного изображения, к форме которого следует привести исследуемый образец.

Рассмотрим алгоритм. Пусть $C = c_1, c_2, ..., c_i, ..., c_n$ и $Q = q_1, q_2, ..., q_i, ..., q_n$ – контура эталонного и обрабатываемого изображений соответственно, где c_i, q_i – точки контуров, а n – количество точек. Будем осуществлять преобразование обрабатываемого изображения таким образом, чтобы его контур с эталонной формой мозга совпал с новым контуром обрабатываемого изображения.

На первом этапе происходит ригидная аффинная трансформация входного изображения, основные шаги которой показаны на Рис. 3. Контур обрабатываемого изображения показан серым цветом, а контур эталонного объекта – черным.

Алгоритм ригидной аффинной трансформации:

– осуществляется переиндексация точек контура приводимого изображения таким образом, чтобы $\sum_{i=1}^{N} d(c_i, q_i) \to \min$, где $d(c_i, q_i)$ есть Евклидово расстояние между c_i и q_i;

– пусть $\overline{c} = \frac{1}{N}\sum_{i=1}^{N} c_i$, $\overline{q} = \frac{1}{N}\sum_{i=1}^{N} q_i$ – центры контуров; сдвиг обрабатываемого изображения осуществляется таким образом, чтобы центры контуров совпадали (Рис. 3,б);

– рассчитывается угол поворота $\alpha = \frac{1}{N}\sum_{i=1}^{N} \alpha_i$, где α_i – угол между соответствующими точками c_i и q_i относительно центра; с целью ускорения операции осуществляется целочисленный поворот эталона на угол α (Рис. 3, в) [6]. Новые координаты (X', Y') точки (X, Y) определяются следующим образом: $X' = (M/L)X + (N/L)Y$; $Y' = -(N/L)X + (M/L)Y$. При повороте, в общем случае, угол α задается тройкой (M, N, L) целых чисел, причем $L^2 = M^2 + N^2$, $M/L = \cos(\alpha)$, $N/L = \sin(\alpha)$.

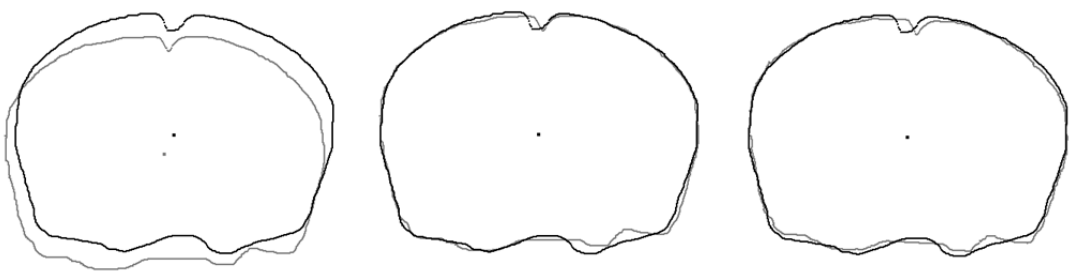

а) б) в)

Рис. 3. Ригидная аффинная трансформация входного изображения
а - начальное положение; б - выравнивание центров; в - поворот контура

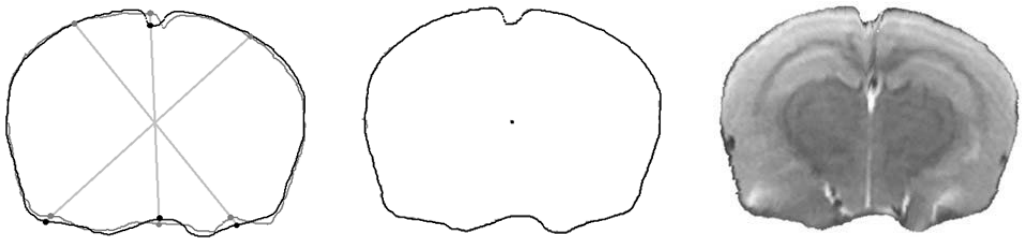

а) б) в)

Рис. 4. Деформация входного изображения
а - начальное положение; б - совпадение контуров; в - результат обработки

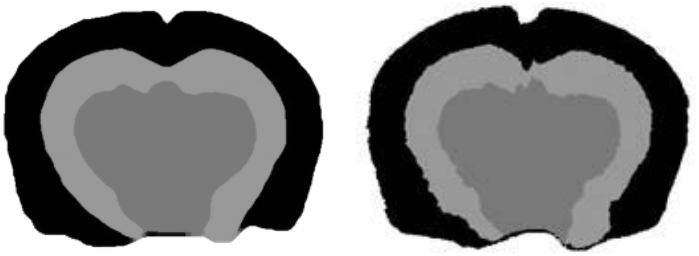

а) б)

Рис. 5. Преобразование с учетом атласа
а - обрабатываемое изображение; б – результат

Таблица синусов и косинусов в виде отношений целых чисел вычисляется заранее и хранится в памяти системы управления поворотом.

На следующем этапе происходит деформация входного изображения так, чтобы контуры головного мозга совпадали. Алгоритм деформации:

– из общего центра проводятся лучи, которые пересекают оба контура (пример построения лучей показан на Рис. 4, а);

– для каждого луча определяется коэффициент растяжения (сжатия) k_i, где i – номер луча; пусть c_i и q_i – точки контуров, принадлежащие одному лучу, тогда $k_i = d(q_i, \overline{q}) / d(c_i, \overline{c})$, причем $\overline{q} = \overline{c}$;

– для каждого луча осуществляется растяжение (сжатие) точек эталона, принадлежащих данному лучу при помощи коэффициента k_i; при этом известно, что точка с целыми координатами (X, Y) принадлежит прямой линии, выходящей из начала координат с коэффициентом наклона $k = (\Delta Y / \Delta X)$, если выполняется условие: $|Y - (\Delta Y / \Delta X \cdot X)| \le \varepsilon$, где $|\varepsilon| \le 0{,}5$ [7].

Результат деформации контура эталона показан на Рис. 4, б, результирующее изображение – на Рис.4, в. В качестве примера рассмотрим задачу приведения изображения с учетом упрощенного атласа мозга крысы с сегментацией на три области интереса. На Рис. 5 показаны исходное изображение и результат искомого преобразования.

После совпадения контуров можно сегментировать целевое изображение для возможного в перспективе решения задачи обучения классификаторов с учетом атласа. Пример сегментации мозга с ишемическим повреждением: на Рис. 6, а показано исходное изображение, а на Рис. 6, б-г - его разбивка на области интереса.

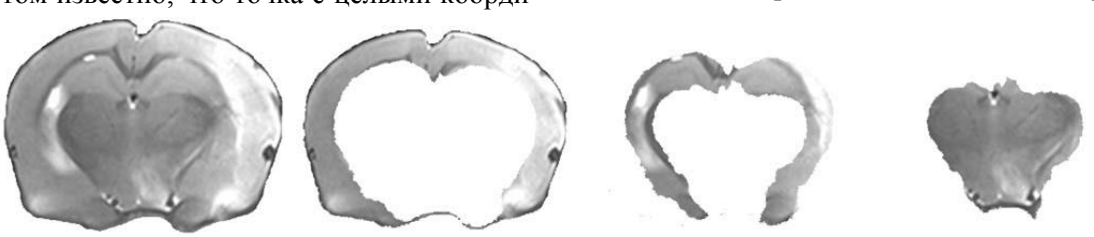

а) б) в) г)

Рис. 6. Сегментация мозга крысы на три части

Разработанный алгоритм сегментации как инструментальное средство предварительной обработки позволяет более качественно распознавать ишемические повреждения, характерные для отдельных анатомических областей, что подтверждается выполненными на данный момент предварительными исследованиями.

2. Инструментальные средства выделения зоны ишемических повреждений

Центральную часть разработанных инструментальных средств составляют алгоритмы выделения характерных признаков и методы сегментации. Важнейшей частью системы классификации и научной визуализации является спектрографический анализ медицинских снимков, служащий для выделения особых зон.

2.1. Метод выделения зоны ишемического поражения на Т2-снимках

Точки результирующего изображения окрашиваются в тот или иной цвет в зависимости от степени близости к региону интереса. Набор регионов интереса задается врачом-экспертом как обучающая выборка. Для обработки данных с томографа задается размер сканирующего окна – ширина и высота. В настоящем исследовании вместо значений яркости, попавших в область под сканирующим окном, использовались признаки, предложенные в работе [8], в том числе текстурные признаки Харалика [9]. Всего имеется семь признаков – три общего назначения и четыре основных.

Признаки общего назначения [8]:

– математическое ожидание μ

$$\frac{1}{MN}\sum_{i=1}^{M}\sum_{j=1}^{N} p_{ij} ,$$

– стандартное отклонение

$$\left[\frac{1}{MN}\sum_{i=1}^{M}\sum_{j=1}^{N}\left(p_{ij}-\mu\right)^2\right]^{\frac{1}{2}},$$

– асимметричность уровня серого

$$\left[\frac{1}{MN}\sum_{i=1}^{M}\sum_{j=1}^{N}\left(p_{ij}-\mu\right)^3\right]^{\frac{1}{3}},$$

где M и N – линейные размеры сканирующего окна, p_{ij} – значение яркости пикселя в i-ой строке и j-ом столбце сканирующего окна.

Основные текстурные признаки Харалика [9]:

– энтропия $\sum_i\sum_j Co(i,j)\log\left(Co(i,j)\right)$,

– энергия $\sum_i\sum_j Co^2(i,j)$,

– контраст $\sum_i\sum_j (i-j)^2\, Co(i,j)$,

– гомогенность $\sum_i\sum_j \frac{Co(i,j)}{1+|i-j|}$,

где $Co(i,j)$ – элемент матрицы смежности уровня серого (Gray-Level Co-occurrence Matrix) в i-ой строке j-го столбца.

Для работы с перечисленными признаками применяется классификатор, использующий расстояние Евклида-Махаланобиса [10]. Расстояние между классом Y (например, классом «ишемическое повреждение») и точкой p (точка – вектор признаков, извлеченных из некоторой позиции сканирующего окна) вычисляется по формуле: $R_G(p,Y)=\sqrt{(p-\bar{y})^T A^{-1}(p-\bar{y})}$,

где матрица $A = C_Y + E$.

Ковариационная матрица C_Y для класса Y вычисляется по формуле:

$$C_y(i,j)=\frac{\sum_{k=1}^{|Y|}\left(s_i^k-\bar{y}_i\right)\left(s_j^k-\bar{y}_j\right)}{|Y|-1},$$

где s_i^k – i-й признак k-й точки из класса Y, $\bar{y}_i$ – математическое ожидание значения этого признака в классе Y.

Для обработки изображений требуется определить два класса – в нашем случае это область здорового мозга («норма», класс Y_1) и область ишемического поражения («поражение», класс Y_2). Каждая область представляется набором небольших эталонных изображений одного из срезов мозга (среза-основы). Из этих изображений извлекаются признаки, необходимые для настройки классификатора. Обработка изображения происходит следующим образом:

– по изображению с шагом в один пиксель движется сканирующее окно;

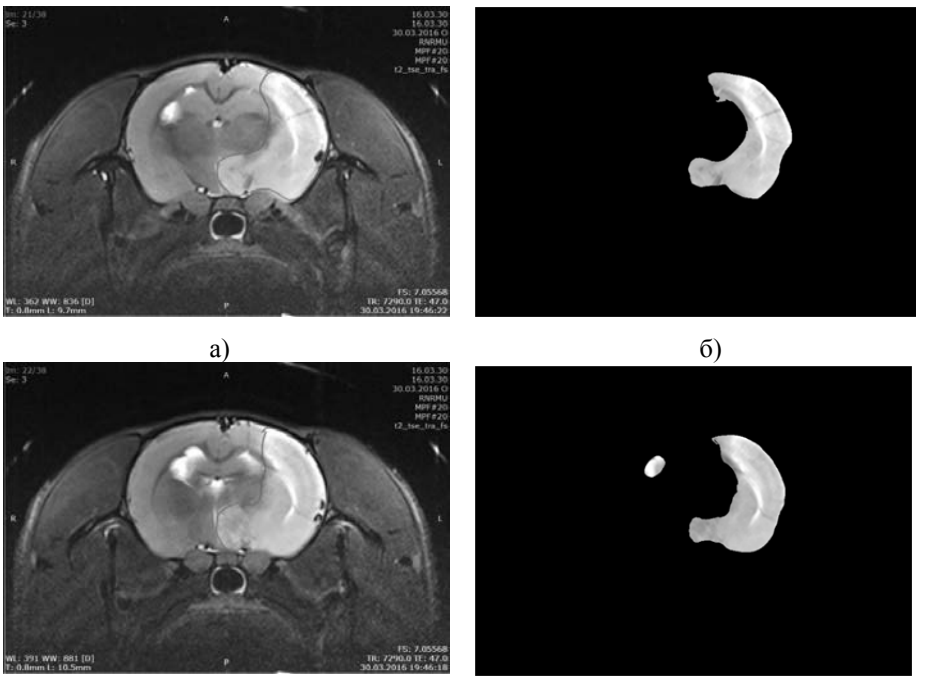

а) б)

в) г)

Рис. 7. Выделение пораженных ишемией участков мозга
а, в - обрабатываемые изображения; б, г - результаты обработки

– яркости пикселей, попавшие в сканирующее окно, используются для вычисления всех признаков;

– вычисляется расстояние Евклида-Махаланобиса от окна до обоих классов, побеждает класс с минимальным расстоянием;

– на результирующем изображении фиксируются только фрагменты, отнесенные к классу «поражение».

В качестве примера на Рис. 7, а показано изображение, которое используется одновременно как срез-основа и как обрабатываемое, а на Рис. 7, б – результат обработки. Изображение на Рис. 7, в используется как обрабатываемое (ранее не учтенное классификатором), изображение на Рис. 7, а остается срезом-основой. Возможны ложные срабатывания классификатора, как это показано на Рис. 7, г.

Дополнительная постобработка путем фильтрации мелких областей позволяет бороться с такими артефактами. Экспериментально подобран размер сканирующего окна, наилучшим образом подходящий под данные, получаемые с используемого томографа 49×49 пикселей. На срезе-основе в проведенных экспериментах выбиралось по 10 непересекающихся окон-эталонов для каждого из классов. Полное время обучения классификатора – менее одной миллисекунды. Каждый срез мозга размером 870×610 пикселей обрабатывается порядка 95 секунд. Текущая реализация работает на процессорах общего назначения (в частности, эксперимент проводился на двухъядерном процессоре Intel Core 2 Duo E6750 @ 2,66 ГГц), в планах адаптация реализации для работы с использованием графических ускорителей Nvidia, что позволит существенно снизить время обработки.

2.2. Метод выделения зоны ишемического поражения на ИКД-снимках

Диффузионно-взвешенная магнитно-резонансная томография [11] отражает диффузионную способность молекул исследуемого объекта. При наличии патологических процессов в головном мозгу исследуемого животного изменяется степень проницаемости клеточных мембран, что непосредственно влияет на общую диффузию молекул воды. С помощью МРТ можно вычислить соответствующий измеряемый коэффициент диффузии (ИКД), характеризующий средний квадрат расстояния, за которое проходят молекулы за единицу времени. Размер среза головного мозга крысы укладывается в пределы изображения 40×30 пикселей,

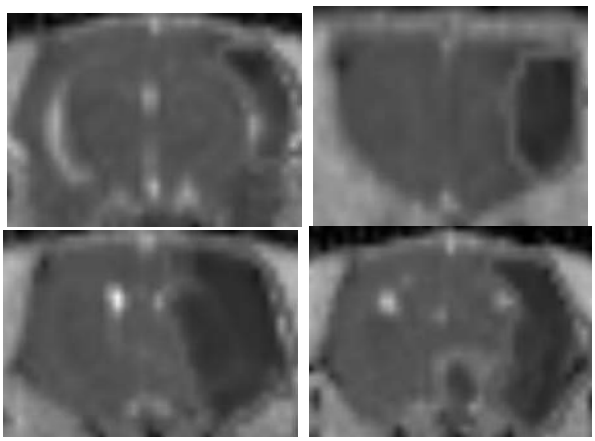

Рис. 8. ИКД-карты мозга крысы
с ишемическим повреждением

что захватывает порядка 1200 точек, каждая из которых характеризуется лишь одним числом – интенсивностью сигнала (или яркостью изображения). Для ишемического повреждения мозга характерно наличие затемненных областей на картах ИКД. На Рис. 8 показаны примеры ИКД-карт животных с ишемическим повреждением мозга, где справа эксперт отметил контур поврежденной области. Эксперт способен достаточно уверенно находить зоны с аномальными тканями.

Однако наша задача заключается в полной автоматизации этого процесса. В качестве инструментального средства для обработки ИКД-изображений применяется аппарат искусственных нейронных сетей. Этот аппарат эффективно использовался авторами в различных медицинских исследованиях [12-14]. В настоящей статье в качестве классификатора применяется сверточная нейронная сеть (СНС) [15]. Считается, что в ее архитектуру заложены наиболее эффективные методы обобщения и классификации информации. Дадим некоторые пояснения. Для задач выделения областей методом тематической закраски размер входного окна СНС равен количеству пикселей в маске, движущейся по исходному изображению, оптимальный размер которой выбирается исходя из конкретной задачи и исходных данных. СНС состоит из чередующихся слоев свертки и субдискретизации, дополненных специализированными слоями, например [16, 17]. На выходе СНС может содержать один или несколько полносвязных слоев. Последний слой нейросети содержит количество нейронов, соответствующее числу классов в решаемой задаче.

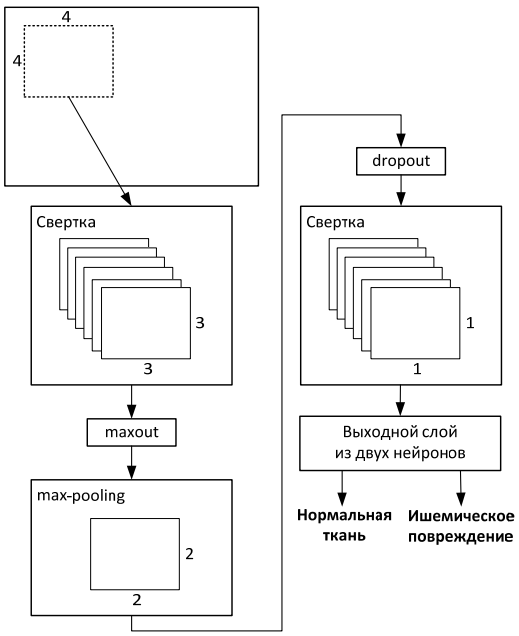

Рис. 9. Архитектура нейронной сети

В выполненных экспериментах в качестве прототипа использовалась нейронная сеть на базе библиотеки nnForge [18], ранее успешно зарекомендовавшая себя в различных прикладных задачах [19-21]. В результате была получена следующая конфигурация нейронной сети (Рис. 9):

– входное окно 4×4 элемента (всего 16 коэффициентов интенсивности);

– слой свертки с картами признаков размером 3×3;

– maxout-слой с нейронами с обучаемой активационной функцией;

– субдискретизирующий слой, выбирающий максимум (max-pooling) [22];

– dropout-слой с регулируемой вероятностью p отключения связей между нейронами (экспериментально установлено: $p = 0{,}05$);

– слой свертки с картами признаков размером 1×1;

– слой нейронов с активационной функцией типа гиперболический тангенс.

Разные карты признаков служат для выделения различных особенностей на изображениях обучающей выборки. Для того, чтобы нейронная сеть смогла запомнить несколько миллионов различных входных окон, пришлось существенно увеличить количество используемых карт признаков. В частности, первый слой свертки содержит две тысячи таких карт, а второй – тысячу. Общее время обучения с использованием видеокарты Nvidia Geforce GTX 980 – не более часа.

В Табл. 1 приведены результаты обработки томографических ИКД-снимков с применением СНС. На серии изображений показаны попарно исходное изображение с очерченной экспертом зоной повреждения и результат обработки нейронной сеть.

Проведенные исследования показали, что СНС выбранной конфигурации достаточно успешно обучается на эталонных снимках, но работает с определенной погрешностью при анализе неизвестных ей образцов. Авторы намерены устранить этот недостаток в своих дальнейших исследованиях. Обученная нейронная сеть способна обрабатывать десятки тысяч изображений в секунду, что обеспечивает хорошую поддержку медика-исследователя.

Табл. 1. Результаты обработки томографических ИКД-снимков с применением СНС

Исходное изображение с предположением о зоне ишемического поражения	Результат обработки оригинального снимка
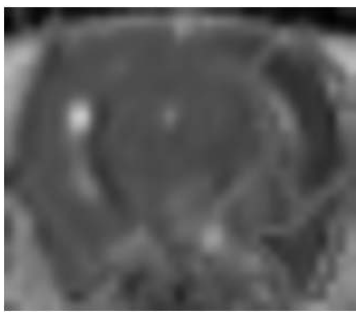	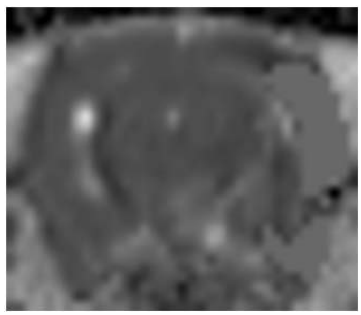
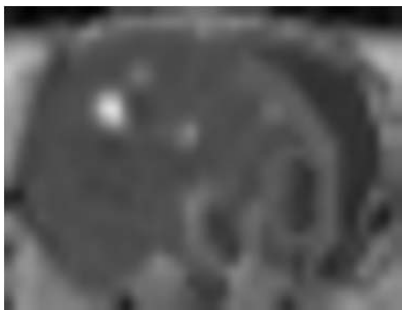	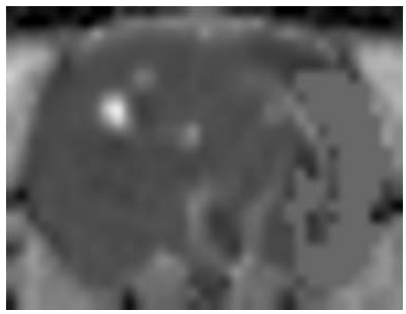
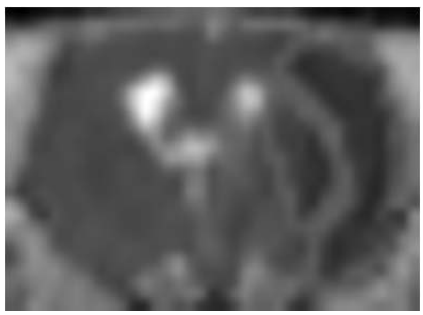	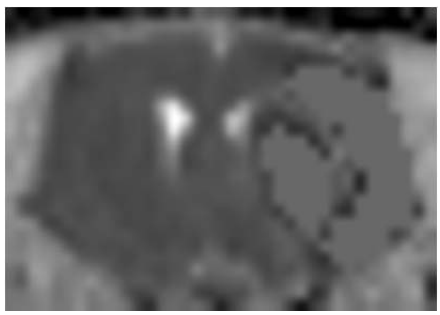
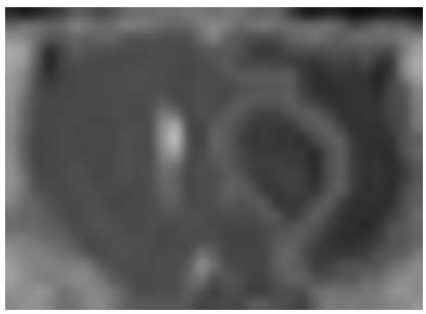	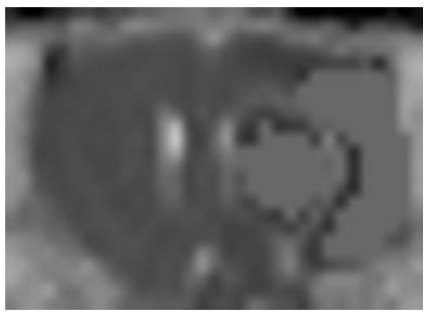

3. Интегрированный программно-аппаратный комплекс

Общая схема разрабатываемого интегрированного программно-аппаратного комплекса представлена на Рис. 10.

Клиентская часть включает в себя графический интерфейс пользователя, обеспечивающий формирование схем решения прикладных задач в парадигме визуально-блочного программирования и отображение результатов обработки биомедицинских данных, полученных с использованием исследовательского оборудования. Серверная часть программно-аппаратного комплекса обеспечивает хранение и многопользовательский доступ к данным проводимых исследований и возможность их высокопроизводительной конвейерно-параллельной обработки в соответствии со сформированными пользователями задачами с использованием ядра программной системы, обеспечивающего вычислительную среду, и модулей обработки, реализующих требуемые алгоритмы.

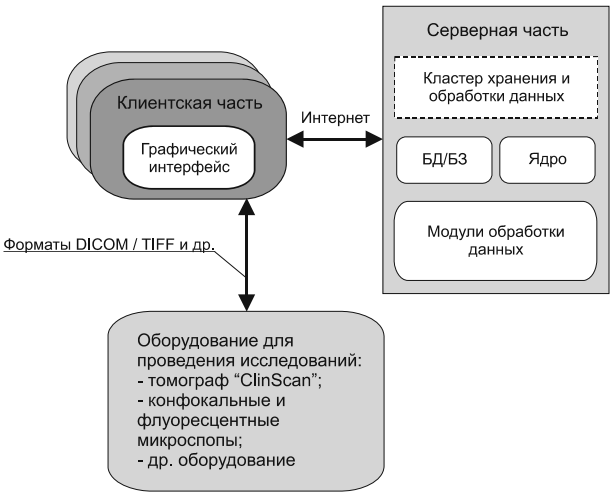

Рис. 10. Схема интегрированного комплекса

Заключение

Проведен комплекс исследований, в которых прошли апробацию различные инструментальные средства для обработки данных МРТ. В результате экспериментов установлено следующее:

– результаты по выравниванию яркостей и приведению одних изображений к другим позволяют проводить корректное сопоставление МРТ-снимков разных образцов;

– наилучшие результаты по выделению зон ишемических повреждений на Т2-снимках достигаются применением метода на основе анализа текстурных характеристик Харалика с применением классификатора на базе расстояния Евклида-Махаланобиса;

– наилучшие результаты по выделению зон ишемических повреждений на ИКД-снимках достигаются применением сверточной нейронной сети.

В настоящее время продолжаются исследования по поиску эффективных инструментов анализа данных МРТ, минимизирующих возможные погрешности выделения зон поражения. В качестве улучшения предлагается учет атласа мозга крысы с выделением основных сегментов. Предполагается, что такой подход позволит более точно настраивать классификатор на ишемическое поражение. Также необходим учет особенностей отдельных срезов головного мозга животных. Для достижения режима реального времени обработки предлагается широкое использование графических и других ускорителей. Ожидается, что общим научным результатом станет разработка моделей, методов и алгоритмов, ориентированных на поддержку проведения научных исследований ишемического поражения тканей мозга.

Авторы выражают благодарность Илье Леонидовичу Губскому (ГБОУ ВПО РНИМУ им. Н.И. Пирогова Минздрава России) за любезно предоставленные данные с томографа.

Литература

1. NITRC: Robust Brain Extraction (ROBEX): Tool/Resource Info [Электронный ресурс]. URL: http://www.nitrc.org/projects/robex (дата обращения: 26.07.2016).
2. BET – FslWiki [Электронный ресурс]. URL: http://fsl.fmrib.ox.ac.uk/fsl/fslwiki/BET (дата обращения: 26.07.2016).
3. NiftySeg – TIG [Электронный ресурс]. URL: http://cmictig.cs.ucl.ac.uk/wiki/index.php/NiftySeg (дата обращения: 26.07.2016).
4. Cabezas M., Oliver A., Llado X., Freixenet J., Cuadra M.B. A Review of Atlas-based Segmentation for Magnetic Resonance Brain Images // Computer Methods and Programs in Biomedicine. Dec 2011. – P. 314-355.
5. Wei Huang. Automatic Affine and Elastic Registration Strategies for Multi-Dimensional Medical Images // A Dissertation in partial fulfillment of the requirements for the Degree of Doctor of Philosophy, Worcester Polytechnic Institute. - 2007. – 140 p.

6. Хачумов М.В. Алгоритмы целочисленной арифметики в задачах расчета траекторного движения // Сборник научных трудов II Всероссийского научно-практического семинара «Беспилотные транспортные средства элементами искусственного интеллекта» (БТС-ИИ-2015) (8-9 октября 2015 г., Санкт-Петербург). - 2015. – С. 130-135.
7. Braccini C., Cocurullo F., Lavagetto F. A Fast Algorithm for High Quality Vector Quantization Codebook Design // Proceeding ICIAP '95 Proceedings of the 8th International Conference on Image Analysis and Processing. – Springer-Verlag London, UK. - 1995. – P. 643-648.
8. Abbadi N.K., Dahir N.S., Alkareem Z.A. Skin texture recognition using neural networks // Proc. Int'l Arab Conf. on Information Technology. - 2008. – P. 1-4.
9. Haralick R.M., Shanmugam K., Dinstein I. Textural features for image classification // IEEE Transactions on Systems, Man and Cybernetics. - 1973. Vol.3. – P. 610-621.
10. Амелькин С.А., Захаров А.В., Хачумов В.М. Обобщенное расстояние Евклида-Махаланобиса и его свойства // Информационные технологии и вычислительные системы. – 2006. – №4. – С. 40-44.
11. Derek K. Jones. Diffusion MRI: Theory, Methods, and Applications // New York: Oxford University Press. - 2011. – 767 p.
12. Талалаев А.А., Тищенко И.П., Фраленко В.П., Хачумов В.М. Анализ эффективности применения искусственных нейронных сетей для решения задач распознавания, сжатия и прогнозирования // Искусственный интеллект и принятие решений. – 2008. –№2. – С. 24-33.
13. Хачумов М.В. Применение искусственных нейронных сетей для автоматической классификации степени заболевания // Сборник научных трудов по материалам III Международной научно-практической конференции «Теоретические и прикладные аспекты современной науки» (Белгород, 30 сентября 2014). Ч.1. – 2014. – С. 203-208.
14. Молодченков А.И., Фраленко В.П., Хачумов В.М. Классификация степени тяжести заболевания на основе искусственных нейронных сетей // Вестник РУДН. Серия Математика. Информатика. Физика. – 2014. – №2. – С. 150-156.
15. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. - 2015, 521 (7553): P.436-444.
16. Maxout Networks [Электронный ресурс]. URL: http://colinraffel.com/wiki/maxout_networks (дата обращения: 26.07.2016).
17. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting, 2014 [Электронный ресурс]. URL: https://www.cs.toronto.edu/~hinton/absps/JMLRdropout.pdf (дата обращения: 26.07.2016).
18. GitHub – milakov/nnForge: Convolutional neural networks C++ framework with CPU and GPU (CUDA) backends [Электронный ресурс]. URL: https://github.com/milakov/nnForge (дата обращения: 26.07.2016).
19. Лебедев А.С., Фраленко В.П., Чэн Г.С., Чжан Г.Л. Экспериментальное исследование задачи поиска сложных ригидных объектов в системе обработки космических снимков «ПС НСКиД» // Современные проблемы науки и образования. – 2015. – №1 [Электронный ресурс]. URL: http://www.science-education.ru/pdf/2015/1/1194.pdf (дата обращения: 26.07.2016).
20. Фраленко В.П., Суворов Р.Е., Овчаренко Р.И., Тихомиров И.А. Автоматическая классификация изображений в задачах фильтрации контента // Информационные технологии и вычислительные системы. – 2015. – №3. – С. 3-11.
21. Агроник А.Ю., Фраленко В.П. Библиотека алгоритмов высокопроизводительной обработки данных от системы технического зрения беспилотного летательного аппарата // Программные системы: теория и приложения. – 2016. – №2. – С. 61-71.
22. Ciresan D.C., Meier U., Masci J. Gambardella L.M., Schmidhuber J. Flexible, High Performance Convolutional Neural Networks for Image Classification // International Joint Conference on Artificial Intelligence. - 2011. – P. 1237-1242.

Фраленко Виталий Петрович. Старший научный сотрудник Лаборатории интеллектуального управления Исследовательского центра ИПС им. А.К. Айламазяна РАН. Окончил ЧОУ ВО «УГП им. А.К. Айламазяна» в 2007 году. Кандидат технических наук. Автор более 60 печатных работ. Область научных интересов: искусственные нейронные сети, машинное обучение, прикладные системы, параллелизм вычислений, защита компьютерных сетей.
E-mail: alarmod@pereslavl.ru.

Хачумов Михаил Вячеславович. Научный сотрудник ИСА ФИЦ ИА РАН. Окончил Российский университет дружбы народов (РУДН) в 2009 году. Канд. физико-математических наук. Автор более 30 печатных работ. Область научных интересов: классификация, кластеризация, метрика, кластерный анализ, слабоструктурированные данные.
E-mail: khmike@inbox.ru.

Шустова Мария Вениаминовна. Аспирант, инженер-исследователь Исследовательского центра ИПС им. А.К. Айламазяна РАН. Окончила ЧОУ ВО «УГП им. А.К. Айламазяна» в 2015 году. Область научных интересов: информационные технологии, методы искусственного интеллекта, биомедицинские исследования. E-mail: m.v.shustova@gmail.com

The tools for automatically finding and visualization of interest areas in the MRI data to support of medical researchers decision-making

V.P. Fralenko, M.V. Khachumov, M.V. Shustova

Abstract. The article gives a detailed description of the techniques that developed by the authors for primary and deep processing of magnetic resonance imaging, directed on detecting areas ischemic defeat in the brain of rats. The composition tools include techniques to bring MRI images of different samples to the normalized form (size, shape, brightness). Another set of tools associated with the detection of anomalies by T2 and MDC images with using of artificial neural networks and specific metrics. To improve the accuracy of recognition tools are configured into sections based on atlases and anatomical features of the rat brain. Tools providing cognitive illumination of the interest zones, in particular ischemic lesion areas. It is assumed that created algorithms and programs will be part of the developing research software system that oriented to support of medical researchers decision-making.

Keywords: magnetic resonance tomography, brain, ischemic lesion, image recognition, visualization, metric, convolutional neural network.

Fralenko V.P., Shustova M.V. Ailamazyan Program Systems Institute of the Russian Academy of Sciences, Yaroslavl Region, Pereslavl-Zalessky District, Veskovo village

Khachumov M.V. Institute for System Analysis of the Federal Research Center “Information and Management” of the Russian Academy of Sciences, Moscow.