

УДК 004.932:616-079

РАЗРАБОТКА МОДЕЛИ АВТОМАТИЧЕСКОГО ОПРЕДЕЛЕНИЯ ГРАНИЦ ГЛИОМЫ ГОЛОВНОГО МОЗГА, НА ОСНОВЕ КОМПЛЕКСНОГО МЕТОДА ОБРАБОТКИ МРТ- И КТ-ИЗОБРАЖЕНИЯ

Соловьева С.Н., Уросова В.С.

*ФГАОУ ВО «Уральский федеральный университет им. первого Президента России Б.Н. Ельцина»,
Екатеринбург, e-mail: vladaurosova14@gmail.com*

В настоящей статье рассмотрена проблема неприменимости существующих алгоритмов обработки и анализа изображения для КТ-, МРТ-изображения глиомы головного мозга. Рассмотрены особенности задачи выделения границы глиомы головного мозга на КТ-, МРТ-изображении. Сформулированы и проанализированы проблемы, обоснованные структурной сложностью глиальных опухолей головного мозга. Показана перспективность и актуальность разработки модели автоматического выделения границы глиомы головного мозга. Проведен литературно – аналитический обзор существующих моделей исследования изображения, на основании которого была выдвинута гипотеза предлагаемого решения. Предложена концепция модели автоматического выделения границ глиомы головного мозга на основе КТ-, МРТ-изображений, включающая современные методы сегментации и фрактального анализа изображений, позволяющих учитывать структурные особенности текстуры изображений глиальных опухолей. Предложена циклическая модель выделения границ глиомы головного мозга с расширенной системой признаков, учитывающей структурные особенности изображения, на основе которых происходит автоматическая коррекция метода сегментации. Разработан пакет алгоритмических моделей, позволяющий проиллюстрировать новизну предлагаемого решения. На основе предложенных алгоритмов в пакете алгоритмических моделей разработан пакет математических моделей. Новизна предлагаемого решения описана математической моделью взаимодействия метода сегментации и фрактального выращивания регионов в блоке «коррекции регионов», где осуществляется коррекция регионов и переход на следующую итерацию алгоритма при помощи анализа системы полученных признаков увеличивают её точность.

Ключевые слова: моделирование, комплексный метод, обработка, анализ, КТ, МРТ, глиома

DEVELOPMENT OF THE MODEL OF AUTOMATIC DETERMINATION OF THE BORDERS OF THE GLIOMA OF THE BRAIN, BASED ON THE COMPLEX METHOD OF PROCESSING MRI AND CT IMAGES

Soloveva S.N., Urosova V.S.

Ural Federal University, Ekaterinburg, e-mail: vladaurosova14@gmail.com

In this article, the problem of the inapplicability of existing image processing and analysis algorithms for the image of brain glioma is considered. Specific features of the problem of isolating the boundaries of brain gliomas on CT and MRI images are considered. The problems substantiated by the structural complexity of glial brain tumors are formulated and analyzed. The prospects and urgency of the development of a model for automatic detection of cerebral glioma boundaries are shown. A literary and analytical review was conducted with the results of the studies on the basis of which the hypothesis of the proposed solution was put forward. The concept of automatic detection of brain glioma boundaries based on CT, MRI images, including modern methods of segmentation and fractal image analysis, allowing to take into account structural features of the texture of images of glial tumors is proposed. A cyclic model for isolating the boundaries of brain glioma with an extended system of features, taking into account the structural features of the image, based on which an automatic correction of the segmentation method occurs, is proposed. A package of algorithmic models is developed, which allows to illustrate the novelty of the proposed solution. Based on the proposed algorithms in the package of algorithmic models, a package of mathematical models is developed. The novelty of the proposed solution is described by the mathematical model of interaction between the segmentation method and the fractal growth of regions in the «region correction» block, where the regions are corrected and the next iteration of the algorithm is performed by analyzing the system of received features. increase its accuracy.

Keywords: modeling, complex method, processing, analysis, CT, MRI, glioma

Современными методами диагностики и визуализации патологий головного мозга являются компьютерная томография (КТ), магнитно-резонансная томография (МРТ) и позитронная – эмиссионная томография (ПЭТ) [1, 2]. При этом изображения внутренней анатомической структуры объекта формируются с помощью различных подходов, в зависимости от выбранного метода диагностики [3]. Подходы к процессу формирования изображения содержат аппарат-

ную и программную составляющие, специфика работы которых приводит к наличию шумов, усреднению значений в пикселях, находящихся на границе двух областей [4]. Вышеперечисленные недостатки приводят к затруднению распознавания на изображениях границ патологии ткани [5].

Проблема выделения границ на медицинских изображениях усложняется не только способами формирования медицинского изображения, но и сложностью вну-

тренней структуры, представленной на изображении. Сложность структуры глиальных опухолей и превалирующее их большинство среди всех первичных опухолей головного мозга объясняется происхождением из клеток нейроглии, вспомогательных клеток нервной ткани, имеющих различную форму и заполняющих пространства между нейронами [6]. Существующие модели исследования изображений, состоящие из различных алгоритмов обработки и анализа изображений [7], не учитывают перечисленные структурные особенности ткани глиальных опухолей.

Неприменимость существующих моделей исследования изображений для выделения границ глиомы головного мозга обусловлена тем, что каждый алгоритм исследования изображения решает свою, локальную задачу, точность и правильность решения которой зависит от эффективности самого алгоритма при заданных условиях.

Так, например, в работе А.А. Потапова [8] говорится о том, что фрактальная обработка изображения справляется с выделением границ объекта на зашумленном изображении. А в работе А.А. Деркач [9] приводится сравнительный анализ методов выделения контуров на медицинских изображениях головы, в результате которого лучшая эффективность определяется у метода Канни. В работе Н.В. Колодникова [10] обоснована значимость использования текстурных признаков для задач сегментации и распознавания объектов на изображении. В работе Н.Ю. Ильясовой [11] предпочтение отдается методам сегментации и кластеризации на основе нейронных сетей.

Задача определения границ глиомы головного мозга обусловлена необходимостью решения поставленных и описанных выше проблем, вызванных методами формирования изображения и структурной сложностью глиомы головного мозга. Задача определения границ глиомы головного мозга не является тривиальной и требует одновременного решения локальных задач, так как при определении границ глиомы головного мозга необходимо не только обосно-

бить область патологии, но и осуществить проверку правильности обоснования при помощи дополнительных инструментов анализа участков изображения. Это необходимо для обеспечения максимальной точности выделения границ глиомы головного мозга, так как этот этап является важной частью процесса предоперационного планирования [12].

Методы исследования изображений можно разделить на две группы – методы обработки и методы анализа изображений, отличающихся друг от друга принципиально разными подходами к процессу выделения объекта на изображении.

Обработка осуществляется путем внесения в исходное изображение тех или иных изменений с целью подготовки изображения для анализа [13]. Обработка изображений, в рамках рассматриваемой проблемы, заключается в решении следующих задач:

- выделение контуров;
- локализация и определение границ объектов изображения;
- сегментация.

Решение поставленных задач осуществляется с помощью методов сегментации, содержащих в себе алгоритмы выделения контуров, локализации и определения границ объектов. Сегментация преследует две цели [14]:

- декомпозиция изображения на части, удобные для последующего анализа;
- изменение формы описания изображения, так как в результате пиксели преобразуются в высокоуровневые структуры, содержащие больше информации и обеспечивающие дальнейший эффективный анализ изображения.

Так как сегментация является основной составляющей при решении поставленной задачи, она должна соответствовать условиям задачи, удовлетворяя поставленным критериям:

- *устойчивость к шумам (У)* – КТ-, МРТ-изображения, с которыми будет осуществляться работа, имеют достаточно высокую степень зашумленности, поэтому одним из требований к алгоритму является устойчивость к шумам.

$$I_y = \begin{cases} 1, & \text{алгоритм устойчив ко многим видам шума} \\ 0,5, & \text{алгоритм устойчив к некоторым видам шума,} \\ 0, & \text{алгоритм неустойчив к видам шума} \end{cases} \quad (1)$$

- *степень автоматизации (СА)* – критерий оценивает зависимость работы алгоритма от оператора.

$$I_{CA} = \begin{cases} 1, & \text{если алгоритм не требует участие оператора} \\ 0, & \text{если алгоритм требует участие оператора} \end{cases}, \quad (2)$$

- сложность реализации (CP) – оценивает сложность написания алгоритма, включающую необходимость использования дополнительных библиотек, параллельный или последовательный способ работы алгоритма, использование определенной платформы, необходимо с дополнительных модулей для разработки.

$$I_{CP} = \begin{cases} 1, & \text{алгоритм низкой степени сложности} \\ 0,5, & \text{алгоритм умеренной степени сложности,} \\ 0, & \text{алгоритм высокой степени сложности} \end{cases}, \quad (3)$$

- самостоятельность алгоритма (CM) – оценивает возможность функционирования алгоритма как самостоятельного метода сегментации.

$$I_{CM} = \begin{cases} 1, & \text{если алгоритм самостоятельный} \\ 0, & \text{если является этапом обработки} \end{cases}. \quad (4)$$

Кортежная модель оценки аналогов методов сегментации

$$OA(C) = \langle O(Y), O(CA), O(CP), O(CM); R \rangle, \quad (5)$$

где О – оценка; А – аналог; С – сегментация; Р – матрица связей.

Таким образом, формула для оценки методов сегментации имеет вид

$$OA(C) = O(CM)*\alpha(CM) + O(CP)*\alpha(CP) + O(CA)*\alpha(CA) + O(Y)*\alpha(Y), \quad (6)$$

где $\sum_{i=1}^N \alpha_i = 1$, α_i – весовой коэффициент i -го критерия.

Было проведено сравнение методов сегментации изображения, представленных в работах [15–17] с использованием метода Томаса Саати (табл. 1).

Таблица 1
Сравнение методов сегментации

		Название метода	Y	CA	CP	CM	α
	На основе анализа границ	Интегральная оценка	0,54	0,31	0,1	0,05	1
		Границные	0	0,31	0,1	0	0,32
		Морфологические	0	0,31	0,1	0	0,32
		Поиск графа	0,27	0	0,05	1	0,32
		Активный контур	0,27	0,31	0	0,05	0,63
		Активный контур и поток вектора градиента	0,27	0,31	0	0,05	0,63
	На основе анализа областей	Пороговая классификация	0	0,31	0,1	0	0,32
		Классификаторы	0,27	0	0,05	0,05	0,28
		Кластерный анализ	0,27	0,31	0,05	0	0,63
		Случайное поле Маркова	0,54	0	0	0,05	0,59
		Наращивание области	0,27	0	0,05	0	0,32
		Метод «разделить и объединить»	0,27	0,31	0	0	0,58
	Смешанные методы	Нейронные сети	0,27	0,31	0	0,05	0,63

Таким образом, каждый из методов имеет свои преимущества и недостатки, при этом нет ни одного метода сегментации, который бы полностью удовлетворял поставленным условиям задачи выделения границ глиомы головного мозга.

Анализ изображения заключается в изучении отдельных характеристик составных частей – фрагментов изображения. Анализ можно осуществлять как на предварительных этапах работы с изображением, так и после решения перечисленных задач. В литературе нет установившегося понятия «анализ изображения», поэтому под ним мы будем понимать определение различных количественных данных изображения – параметров [14]. Так как МРТ-изображение является растровым текстурным изображением и для его анализа существует множе-

ство инструментов, то будут рассмотрены методы текстурного анализа изображения.

Рассмотренные методы текстурного анализа изображения должны соответствовать следующим критериям:

- сложность реализации (СР) – критерий оценивает сложность написания алгоритма, включающую необходимость использования дополнительных библиотек, параллельный или последовательный способ работы алгоритма, использование определенной платформы, необходимость дополнительных модулей для разработки.

$$I_{CP} = \begin{cases} 1, & \text{низкая степень сложности реализации} \\ 0,5, & \text{средняя степень сложности реализации,} \\ 0, & \text{высокая степень сложности реализации} \end{cases} \quad (7)$$

- вычислительная сложность (ВС) – данный критерий включает в себя быстродействие алгоритмов, трудоемкость работы алгоритмов, использование графического ядра и т.п.

$$I_{BC} = \begin{cases} 1, & \text{низкая степень вычислительной сложности} \\ 0,5, & \text{средняя степень вычислительной сложности,} \\ 0, & \text{высокая степень вычислительной сложности} \end{cases} \quad (8)$$

- возможность анализа полной сцены изображения (АПС) – данный критерий необходим для определения того, на каком из этапов можно использовать рассматриваемые методы, способны ли они анализировать изображение целиком или только отдельно выделенные объекты.

$$I_{APS} = \begin{cases} 0, & \text{возможен анализ выделенных частей изображения} \\ 1, & \text{возможен анализ полного изображения и его частей.} \end{cases} \quad (9)$$

Картечная модель оценки аналогов методов текстурного анализа

$$OA(TA) = \langle O(CP), O(BC), O(APC), R \rangle, \quad (10)$$

где О – оценка; А – аналог; ТА – текстурный анализ; Р – матрица связей.

Таким образом, формула для оценки методов сегментации имеет вид

$$OA(TA) = O(CP)*\alpha(CP) + O(BC)*\alpha(BC) + O(APC)*\alpha(APC), \quad (11)$$

где $\sum_{i=1}^N \alpha_i = 1$, α_i – весовой коэффициент i -го критерия

Было проведено сравнение методов текстурного анализа изображения, рассмотренных в работах [18–20] с использованием метода Томаса Саати (табл. 2).

Таблица 2
Сравнение методов текстурного анализа

	СР	ВС	АПС	α
Интегральная оценка	0,6	0,32	0,08	1
Статистические	0	0,16	0,08	0,24
Структурные	0,3	0	0,08	0,38
Фрактальные	0,3	0,16	0	0,46
Спектральные	0,3	0	0,08	0,38

Анализируя таблицу, было установлено, что ни один из рассмотренных методов текстурного анализа изображения не удовлетворяет условиям поставленной задачи в полной мере, так как в представленной таблице в соответствующей строке есть ноль.

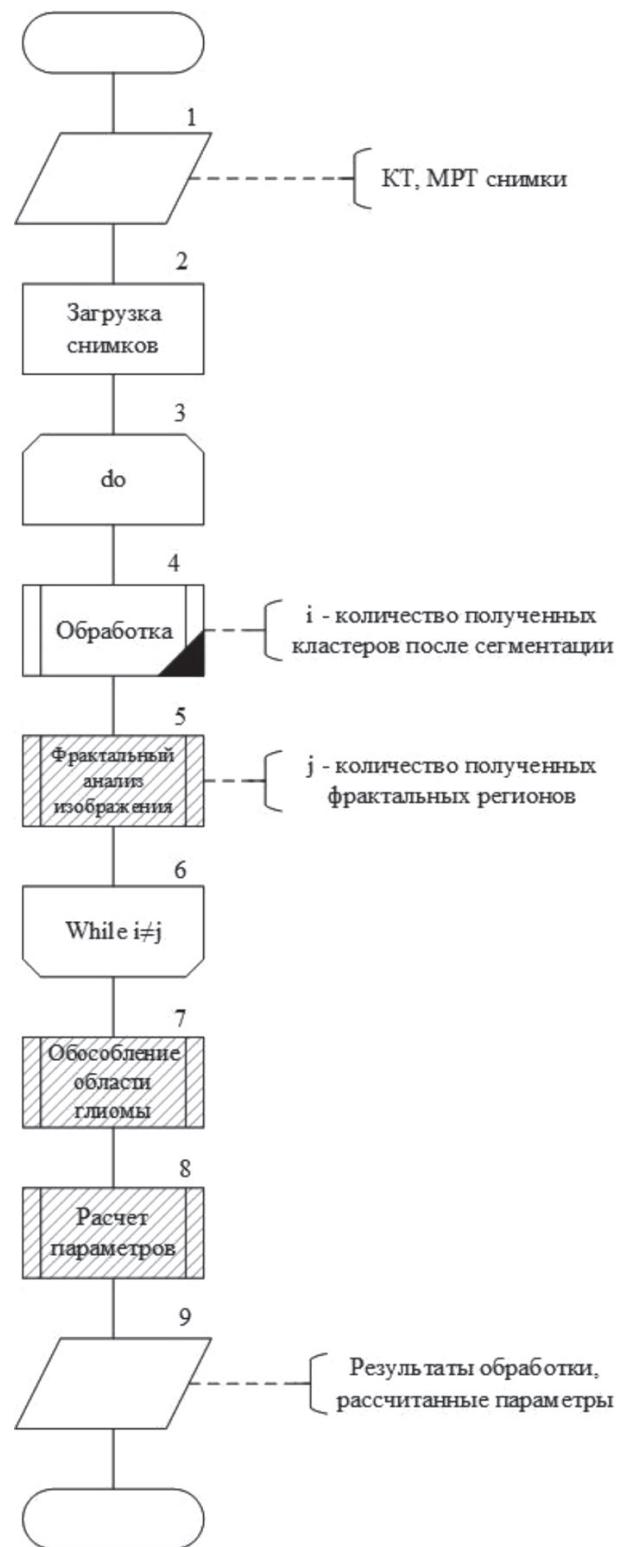


Рис. 1. Алгоритмическая модель предлагаемого решения

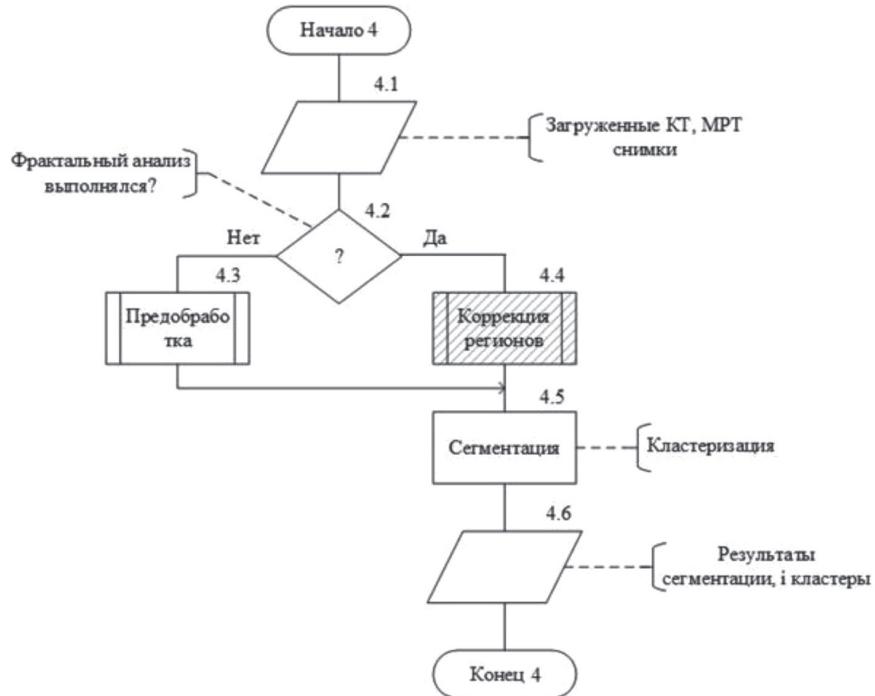


Рис. 2. Алгоритмическая модель блока «Обработка»

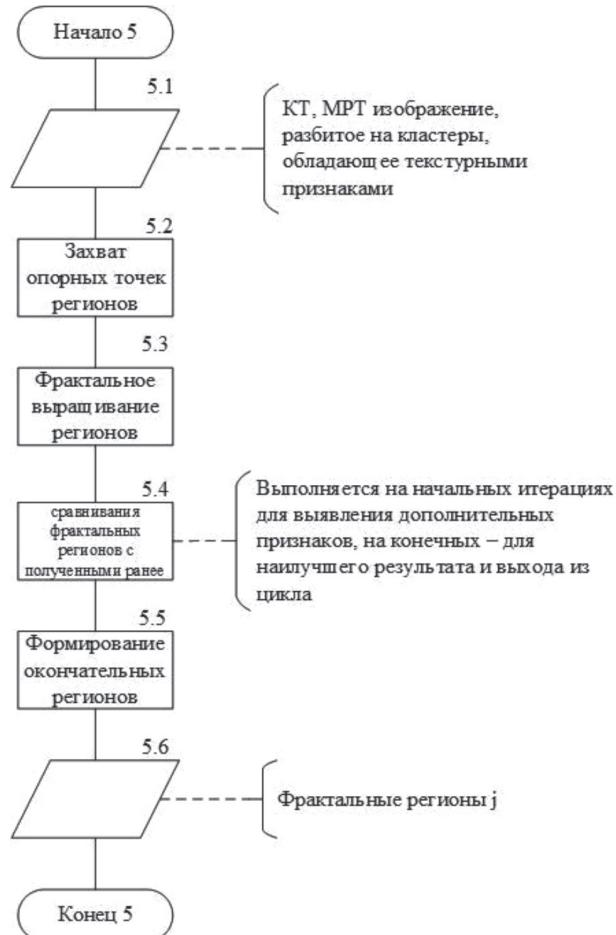


Рис. 3. Алгоритмическая модель блока «Фрактальный анализ изображения»

Приведенная оценка существующих методов исследования изображения позволяет сделать вывод о том, что нет метода исследования изображений, полностью удовлетворяющего критериям и условиям поставленной задачи выделения границ глиомы головного мозга по КТ-, МРТ-изображениям. Анализ полученных результатов оценки двух групп аналогов показал, что можно выделить две позиции: *кластерный анализ* в качестве аналога метода сегментации и *фрактальный анализ* – в качестве аналога метода текстурного анализа изображения.

Отсутствие метода, полностью удовлетворяющего критериям и условиям поставленной задачи выделения границ глиомы головного мозга, является предпосылкой к выдвижению гипотезы о том, что необходимо разработать комбинированный и специализированный инструментарий, на основе определенных критериев алгоритмов исследования изображения. Необходимо создать общую модель, учитывающую структурные особенности глиом головного

мозга и нивелирующую описанные выше проблемы.

Для описания специфики предлагаемого решения был разработан пакет алгоритмических и математических моделей. На рис. 1 представлена алгоритмическая модель предлагаемого решения для выделения границ глиомы головного мозга.

На рис. 2 представлена алгоритмическая модель блока «Обработка».

На рис. 3 представлена алгоритмическая модель блока «Фрактальный анализ изображения».

На рис. 4 представлена алгоритмическая модель подфункции «коррекция регионов» блока «обработка».

Представленный пакет алгоритмических моделей отражает специфику предлагаемого решения поставленной проблемы, которое позволяет запоминать и учитывать новые признаки регионов, полученные с помощью фрактального анализа, дополняющие выбранный метод сегментации и увеличивающие её точность.

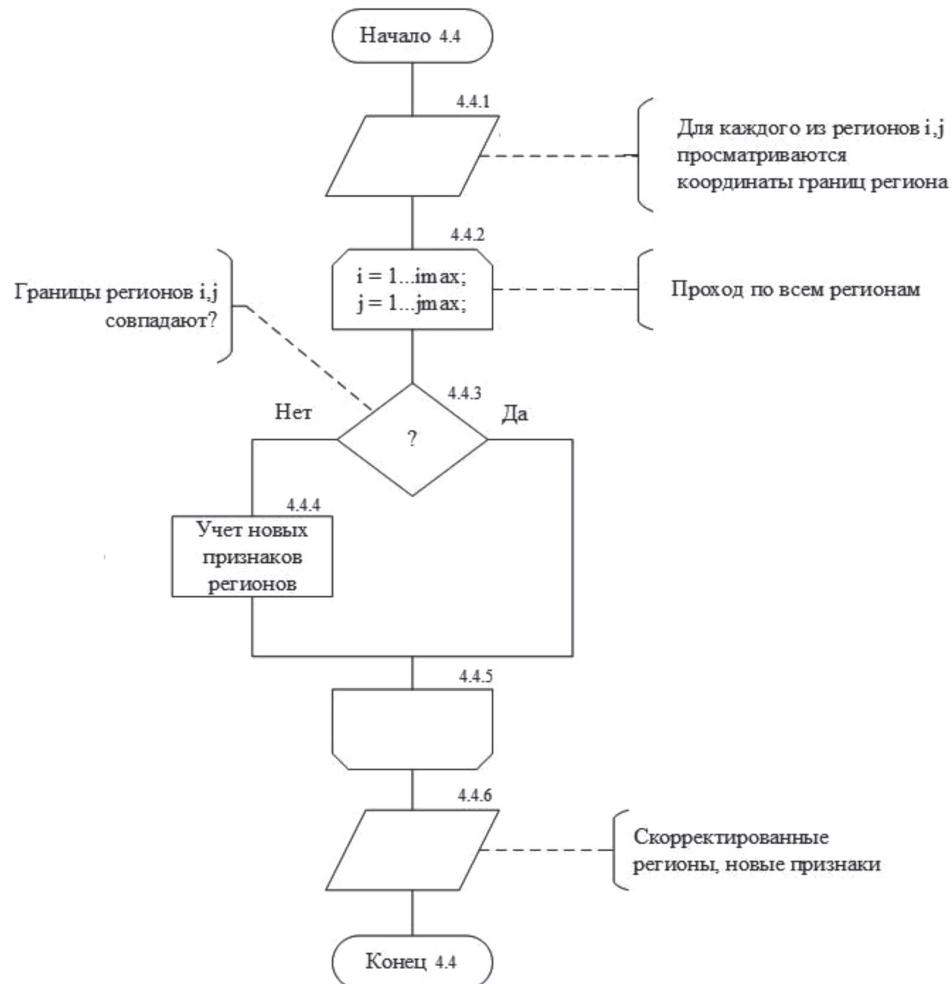


Рис. 4. Алгоритмическая модель подфункции «Коррекция регионов» блока «Обработка»

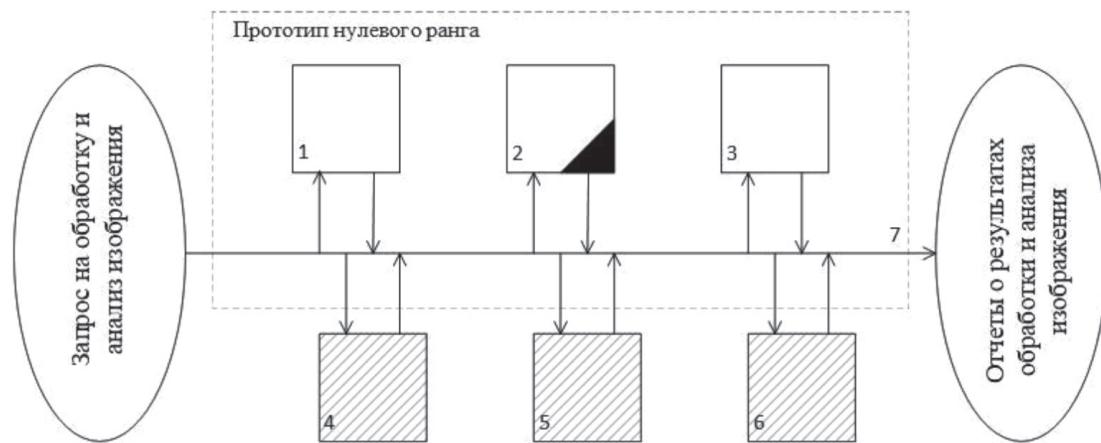


Рис. 5. Структурная модель предлагаемого решения

На основе представленных алгоритмических моделей разработан пакет математических моделей, каждая из которых описывает блоки структурной модели предлагаемого решения (рис. 5).

На рис. 5 используются следующие обозначения:

- 1 – блок загрузки изображения;
- 2 – блок обработки изображения (предобработка, сегментация, коррекция регионов);
- 3 – блок визуализации результатов;
- 4 – блок фрактального анализа изображения;

5 – блок обоснования области глиомы от фона;

6 – блок расчета параметров выделенной области глиомы;

7 – общий интерфейс.

Входными данными решаемой задачи выделения границ глиомы головного мозга являются КТ-, МР-изображения, процесс формирования которых описан в [1]. КТ-, МРТ-изображения являются цифровыми изображениями. В условиях поставленной задачи, под цифровым изображением будем понимать матрицу размером $M \times N$ вида

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, N-1) \\ f(1,0) & f(1,1) & \dots & f(1, N-1) \\ \vdots & \vdots & & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1, N-1) \end{bmatrix}. \quad (12)$$

Правая часть этого равенства и есть по определению цифровое изображение. Каждый элемент матрицы называется пикселям.

Первым шагом обработки изображения является его предобработка, осуществляется путем применения различных масок, фильтров, линейных преобразований и т.п., описанных в [15]. Так как в рассматриваемой задаче входными данными являются КТ-, МРТ-изображения, выбор начальных стадий обработки изображений осуществляется исходя из свойств данного вида изображений [14], а именно:

- изображения имеют низкое разрешение и высокую степень зашумленности;

– имеет место эффект «частичного объема», что осложняет задачу определения точной границы.

Показатель соотношения сигнала к шуму определяется формулой

$$SNC = \frac{S}{\delta}, \quad (13)$$

где S – среднее значение сигнала; δ – стандартное значение отклонения сигнала от фона.

Таким образом, нами был осуществлен выбор этапов предварительной обработки изображения. Результаты выполнения этапов представлены на рис. 6, а.

Устранение фона

Вычисляется среднее значение неравномерного фона \hat{n} по периметру изображения L , поскольку предполагается, что интересующее изображение расположено в центре кадра

$$\hat{n} = L^{-1} \sum_{i=1}^L n_i, \quad (14)$$

где n_i – значение фона в i -м элементе разрешения по периметру изображения.

Суммирование в (14) происходит только по периметру прямоугольного изображения. Далее формируется оценка отфильтрованного изображения по следующему правилу

$$J_k = \begin{cases} J_{k-1} - \hat{n}_{k-1}, & \text{при } J_{k-1} > \hat{n}_{k-1} \\ 0, & \text{при } J_{k-1} < \hat{n}_{k-1} \end{cases}. \quad (15)$$

При двух- или трехкратном применении данного фильтра к изображению практически весь аддитивный фон устраняется.

Повышение резкости

Обработанное изображение по формулам (14, 15) подвергается преобразованию Фурье [15], осуществляется переход в область пространственных частот $F_k(\vec{w})$. Далее осуществляется повышение высоких пространственных частот путем возведения полученного спектра в степень, показатель которой α лежит в диапазоне $(0 \dots 1)$. Указанную процедуру можно записать следующим образом:

$$F_{k+1}(\vec{w}) = [F_{k+1}(\vec{w})]^\alpha. \quad (16)$$

Затем осуществляется обратное Фурье-преобразование от $F_{k+1}(\vec{w})$ и получается оценка изображения J_{k+1} с резко выделенными деталями.

Фильтр Винера

Фильтры Винера усиливают интенсивность сигнала от выявленных очаговых изменений, что позволяет повысить точность сегментации патологии. Этот метод менее подвержен влиянию помех. Используется информация о спектральных плотностях мощности изображения и шума.

Спектральная плотность сигнала определяется соотношением

$$S_H(v) = F[R(\omega)], \quad (17)$$

где $R(\omega) = \int I(x)I(x-\omega)dx$ – автокорреляционная функция.

Взаимная спектральная плотность сигнала определяется соотношением

$$S_{H'}(v) = F[R(\omega)], \quad (18)$$

где $R(\omega) = \int I(x)I'(x-\omega)dx$ – функция взаимной корреляции.

При построении фильтра Винера ставится задача минимизации среднеквадратичного отклонения обрабатываемого изображения от предмета

$$E\left\{\left[I(x,y) - I'(x,y)\right]^2\right\} = \min, \quad (19)$$

где $E\{\cdot\}$ – математическое ожидание.

Преобразуя эти выражения, можно показать, что минимум (19) достигается, когда передаточная функция определяется следующим выражением

$$D(v_x, v_y) = \frac{S_{H'}(v_x, v_y)}{S_H(v_x, v_y)}. \quad (20)$$

Если шума на изображении нет, то спектральная плотность функции шума равна 0 и фильтр Винера превращается в обычный обратный фильтр.

На этом шаге исходное изображение приобретает улучшенное визуальное представление, при этом его обработка осуществляется автоматически и с минимальными потерями информации об исходном изображении.

Следующим шагом являются сегментация изображения и фрактальный анализ, отражающие основную специфику разрабатываемой модели.

– Этап *сегментации* исходного изображения имеет вид

$$\hat{S}(a) = \{K_1(A_1), \dots, K_i(A_i)\} : \forall K_i(A_i)$$

$$\text{удовлетворяет } Q = \{Q_i\}, \quad (21)$$

где Q – множество критериев метода сегментации.

– Этап *фрактального анализа изображения* имеет вид

$$\hat{F}(K'_i(A'_i)) = \{K'_1(A'_1), \dots, K'_j(A'_j)\} :$$

$$\forall K'_j(A'_j) \text{ удовлетворяет } Q = \{Q_i\}$$

$$\text{и } H = \{H_i\}, \quad (22)$$

где H – множество критериев для выращивания фрактального региона.

– Этап *определения ошибки сегментации* и запоминания новых признаков регионов, удовлетворяющих критериям. Формально представим в виде

$$\{K_i(A_i)\} - \{K'_j(A'_j)\} \neq \emptyset. \quad (23)$$

Обозначения:

- a – множество всех пикселей изображения;
 $A = \{A_i\}$ – подмножество пикселей, удовлетворяющих критериям сегментации;
 $A' = \{A'_j\}$ – подмножество пикселей, удовлетворяющих критериям фрактального выращивания регионов;
 \hat{S} – операция сегментации над множеством A ;
 \hat{F} – операция фрактального выращивания регионов над множеством A' ;
 K – множество кластеров, полученных после процедуры \hat{S} ;
 K' – множество регионов, полученных после процедуры \hat{F} .

Проводимая на первой итерации сегментация выполнена с ошибкой, найденной с помощью оценки разности границ кластеров и фрактальных регионов. Необходимо запомнить новые признаки H, Q и вернуться к этапу сегментации, но уже имея дополнительные учитываемые признаки для выполнения новой итерации сегментации.

Взаимодействие этапов сегментации и фрактального выращивания регионов отображает специфику предлагаемого решения, позволяющего запоминать и учитывать новые признаки регионов, полученные с помощью фрактального анализа.

Описанный этап сегментации (21) должен выполняться автоматически, без ввода дополнительных условий и статических критериев. При этом на выходе должно быть получено разбитое на кластеры изображение, каждый кластер которого хранит в себе информацию о пикселях, принадлежащих ему, такую как интенсивность сигнала пикселей, знания о соседних пикселях, пиксели на границах. Кластерное разбиение изображения на этом этапе является подготовкой к фрактальному анализу, который заключается во фрактальном выращивании регионов из центра масс автоматически определенных кластеров.

Удовлетворяя специфике предлагаемого решения, используется алгоритм кластеризации нечетких k -средних [21]. Нечеткая кластеризация заключается в нахождении нечеткого разбиения элементов исследуемой совокупности элементов на T нечетких кластеров и формирования соответствующих им значений функций принадлежности. Функция принадлежности указывает на степень уверенности в том, что элементы некоторого множества принадлежат заданному нечеткому множеству, и должна удовлетворять условию

$$\mu_{A_j}(a_i) \geq 0, \forall j \in [1, T], \forall a_i \in A, \quad (24)$$

где A – анализируемое изображение.

Из векторов значения признаков формируется матрица данных

$$D = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_q^1 \\ x_1^2 & x_2^2 & \dots & x_q^2 \\ \dots & \dots & \dots & \dots \\ x_1^n & x_2^n & \dots & x_q^n \end{bmatrix}. \quad (25)$$

Постановка задачи нечеткого кластерного анализа формулируется таким образом: на основе исходных данных D определить такое нечеткое разбиение множества A на заданное число нечетких кластеров, при котором достигается экстремум некоторой целевой функции среди всех нечетких разбиений.

На функции принадлежности накладываются дополнительные условия нормировки

$$\sum_{j=1}^T \mu_{A_j}(a_i) = 1, \forall a_i \in A, \quad (26)$$

$$\sum_{i=1}^T \mu_{A_j}(a_i) = 1, \forall i \in [1, T], \quad (27)$$

где $T \in N$ – число кластеров, $T > 1$, – отсутствие пустых кластеров.

Для каждого нечеткого кластера вводится q – мерных векторов центра кластеров $c_i = [c_1^j, c_2^j, \dots, c_q^j], \forall j \in [1, T]$, каждый компонент которого определяется в соответствии с уравнением

$$c_l^j = \frac{\sum_i [\mu_{A_j}(a_i)]^m x_l^i}{\sum_i [\mu_{A_j}(a_i)]^m} \quad \text{для } \forall j \in [1 \dots T], \forall p_l \in P, \quad (28)$$

где m – экспоненциальный вес.

Целевая функция – сумма квадратов взвешенных отклонений координат объектов кластеризации от центров искомых нечетких кластеров:

$$\epsilon(A, c_l^j) = \sum_{i=1}^n \sum_{j=1}^T [\mu_{A_j}(a_i)]^m \sum_{l=1}^q (x_l^i - c_l^j)^2. \quad (29)$$

Задача нечеткой кластеризации – найти матрицу U значений функции принадлежности объектов кластеризации нечетким кластерам, обеспечивающую получение минимума целевой функции (29). Результаты работы сегментации на первой итерации приведены на рис. 6, б.

Используемый фрактальный анализ изображения (22) является ключевым в предлагаемом решении, так как модель фрактальной оценки кластеров используется для уменьшения ошибки сегментации. При

этом для каждого полученного кластера необходимо определить признаки локальной фрактальной модели, вырастить регион из центра кластера с учетом новых признаков, оценить степень расхождения границ кластера и региона и провести повторную сегментацию с учетом новой информации о текстуре.

Для разработки модели фрактальной оценки кластеров был использован алгоритм сегментации изображений с использованием фрактальной размерности, оцениваемой с помощью коэффициентов вейвлет-разложения, представленный в [22]. Данный метод использует вектор признаков, составленный из оценок фрактальной размерности по трем направлениям (горизонтальное, диагональное и вертикальное) и нескольким уровням вейвлет-разложения. Тот факт, что производится работа с дискретными сигналами, означает отсутствие бесконечного количества уровней изображения. Следовательно, имеется конечное число значений масштаба, на которых возможно произвести вычисление оценки фрактальной размерности. Таким образом, в качестве вектора признаков для исследуемого участка изображения используется последовательность значений, полученная при разных уровнях разрешения и ориентациях.

Для каждого элемента изображения (полученных ранее кластеров) используется следующая формула:

$$D_{\theta,v}(p) = \frac{\log \left\{ \sum_{u \in W_{\theta,v}[N(p)]} |u| \sqrt{2^{-v}} \right\}}{\log(v^2)} = \frac{\log \left\{ \sum_{u \in W_{\theta,v}[N(p)]} |u| \sqrt{2^{-v}} \right\}}{v * C}, \quad (30)$$

где $N(p) \in K$ – окно изображения, окружающее пиксель p внутри кластера, представляющее функцию, для которой вычисляется фрактальная размерность; $v \in \{0, \dots, \log_2 m\}$ – уровни декомпозиции (разрешения) дискретного вейвлет-преобразования кластера, $\theta \in \{\text{горизонтальный, вертикальный, диагональный}\}$; $W_{\theta,v}$ – вейвлет-коэффициенты изображения; $C = \log 2$ – постоянная.

Вычисляемая в данной работе при помощи вейвлет-преобразования оценка фрактальной размерности по формуле (30) используется для формирования многомерного массива признаков.

Выращивание фрактальных регионов происходит аналогично описанному выше алгоритму кластерного анализа с учетом добавления новых признаков в матрицу

$$D = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_q^1 \\ x_1^2 & x_2^2 & \dots & x_q^2 \\ \dots & \dots & \dots & \dots \\ x_1^n & x_2^n & \dots & x_q^n \end{bmatrix}. \quad (31)$$

Этап коррекции регионов заключается в оценке полученных на этапе фрактального анализа областей. Коррекция производится с помощью применения гистограмм полученных кластеров и регионов. Если один и тот же элемент входит в кластер, но при этом его фрактальная размерность отличается от элементов данного региона, то необходимо учесть эту разность. Процедура повторяется для каждого элемента. Формируется массив новых признаков элементов.

На последней итерации предложенного алгоритма изображение полностью разбито на окончательные кластеры, при этом подсчитаны фрактальные размерности для каждого из них (рис. 6, в).

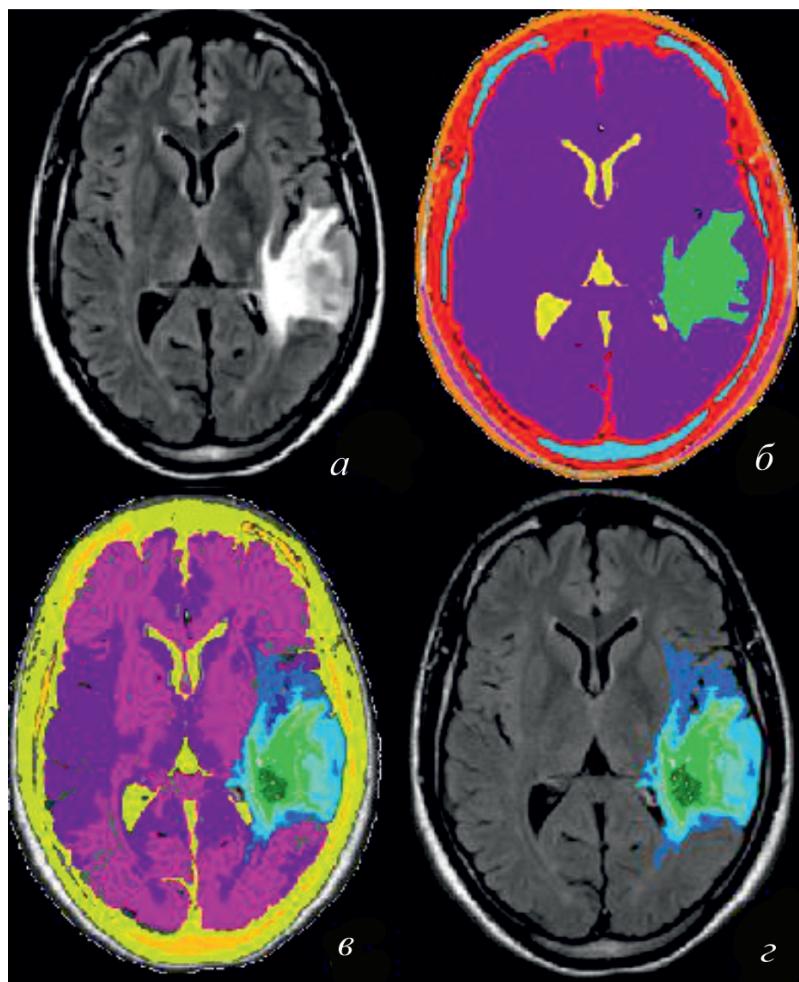
Этап обособления области глиомы головного мозга от фона осуществляется с помощью построения гистограммы конечного обработанного и проанализированного изображения. Кластер, описывающий глиому, определяется как участок гистограммы с нехарактерным фрактальным распределением (рис. 6, г).

Таким образом, предлагаемое решение позволяет запоминать и учитывать новые признаки регионов, полученные с помощью фрактального анализа, которые дополняют выбранный метод сегментации и увеличивают её точность. В ходе работы были получены как научные, так и практические результаты:

1. Рассмотрены особенности задачи выделения границы глиомы головного мозга на КТ-, МРТ-изображении. Сформулированы и проанализированы проблемы, вызванные структурной сложностью глиальных опухолей головного мозга. Определена перспективность и актуальность разработки модели автоматического выделения границы глиомы головного мозга.

2. Предложена концепция модели автоматического выделения границ глиомы головного мозга на основе КТ-, МРТ-изображений, включающая современные методы сегментации и фрактального анализа изображений, позволяющих учитывать структурные особенности текстуры изображений глиальных опухолей.

3. Предложена циклическая модель выделения границ глиомы головного мозга с расширенной системой признаков, учитывающей структурные особенности изображения, на основе которых происходит автоматическая коррекция метода сегментации.



*Рис. 6. Результат работы алгоритма предлагаемого решения
(а – результат работы блока предварительной обработки; б – результат работы блока сегментации на первой итерации; в – результат работы блока коррекции регионов;
г – результат работы блока обособления области глиомы)*

4. На основе предложенных алгоритмов в пакете алгоритмических моделей разработан пакет математических моделей. Новизна предлагаемого решения описана математической моделью взаимодействия метода сегментации и фрактального выращивания регионов в блоке «коррекции регионов», где осуществляется коррекция регионов и переход на следующую итерацию алгоритма при помощи анализа системы полученных признаков.

Список литературы

1. Современные технологии нейровизуализации (лекция) / М.В. Кротенкова [и др.] // Радиология-практика. – 2017. – № 2. – С. 47–63.
2. Дюкарев В.В. Позитронно-эмиссионная томография: сущность метода, достоинства и недостатки // Бюллетень медицинских интернет-конференций. – 2013. – Т. 3, № 11. – 1196 с.
3. DICOM Viewer изнутри. Воксельный рендер [Электронный ресурс]. – URL: <https://habrahabr.ru/post/252429> (дата обращения: 09.02.18).
4. Марусина М.Я., Волгарева А.П. Подходы к разработке методов автоматической сегментации томографических изображений // Фундаментальные и прикладные проблемы техники и технологии. – 2015. – Т. 1, № 5. – С. 136–141.
5. Возможности постобработки диагностических КТ- и МРТ-изображений на персональном компьютере / Л.Г. Розенфельд [и др.] // Украинский медицинский журнал. – 2006. – № 6. – С. 56.
6. Скворцова Т.Ю., Бродская З.Л., Савинцева Ж.И. Современные методы нейровизуализации в дифференциальной диагностике лучевых поражений головного мозга у больных с церебральными опухолями // Бюллетень сибирской медицины. – 2011. – Т. 10, № 4. – С. 130–136.
7. Гонсалес Р. Цифровая обработка изображений / Р. Гонсалес, Р. Будс. – М.: Техносфера, 2005. – 1072 с.
8. Потапов А.А. Фракталы, скейлинг и дробные операторы как основа новых методов обработки информации и конструирование фрактальных радиосистем // Технология и конструирование в электронной аппаратуре. – 2008. – № 5. – С. 3–19.

9. Деркач А.А., Привалов М.В. Обнаружение границ объектов на изображениях с артефактами JPEG-сжатия (на примере снимков магниторезонансной томографии). – 2010. URL: <http://ea.dgstu.donetsk.ua:8080/jspui/handle/123456789/3831> (дата обращения: 15.02.2018).
10. Колодникова Н.В. Обзор текстурных признаков для задач распознавания образов // Доклады Томского государственного университета систем управления и радиоэлектроники. – 2004. – № 1. – С. 113–123.
11. Ильясова Н.Ю., Куприянов А.В., Храмов А.Г. Информационные технологии анализа изображений в задачах медицинской диагностики. – М.: Радио и связь, 2012. – С. 424.
12. Розуменко В.Д., Розуменко А.В. Применение мультиmodalной нейронавигации в хирургии опухолей головного мозга // Украинский нейрохирургический журнал. – 2010. – № 4. – С. 51–57.
13. Коротков К.Г., Крылов Б.А. Параметрический анализ полутоновых изображений // Научно-технический вестник информационных технологий, механики и оптики. – 2002. – № 6. – С. 153–155.
14. Шапиро Л. Компьютерное зрение / Л. Шапиро, Дж. Стокман. – М.: БИНом, 2006. – 752 с.
15. Магонов А.П., Ильвес А.Г., Катаева А.В. Автоматическая сегментация МРТ-изображений головного мозга: методы и программное обеспечение // ВИЧ-инфекция и иммуносупрессии. – 2014. – Т. 6, № 3. – С. 73–77.
16. Gupta D., Anand R.S., Tyagi B. A hybrid segmentation method based on Gaussian kernel fuzzy clustering and region based active contour model for ultrasound medical images // Biomedical Signal Processing and Control. – 2015. – Т. 16. – С. 98–112.
17. Winter M.R. et al. Computational image analysis reveals intrinsic multigenerational differences between anterior and posterior cerebral cortex neural progenitor cells // Stem cell reports. – 2015. – Т. 5, № 4. – С. 609–620.
18. Bagri N., Johari P.K. A comparative study on feature extraction using texture and shape for content based image retrieval // International Journal of Advanced Science and Technology. – 2015. – Т. 80. – С. 41–52.
19. Фисенко В.Т., Фисенко Т.Ю. Фрактальные методы сегментации текстурных изображений // Известия высших учебных заведений. – 2013. – Т. 56, № 5. – С. 63–70.
20. Al-Saidi N.M.G., Mohammed A.J., Ahmed A.M. Fuzzy fractal dimension based on escape time algorithm // Applied Mathematical Sciences. – 2014. – Т. 8, № 3. – С. 117–129.
21. Ершов К.С., Романова Т.Н. Анализ и классификация алгоритмов кластеризации // Новые информационные технологии в автоматизированных системах. – 2016. – № 19. – С. 274–279.
22. Zhuang X., Meng Q. Локальная нечеткая фрактальная размерность и ее применение в медицинской обработке изображений // Искусственный интеллект в медицине. – 2004. – Т. 32, № 1. – С. 29–36.