

¹ Maaayed F. Al-Rawi, ² Muhanned AL-Rawi

Image Segmentation of Brain Tumors Using K-means Cluster Technique

¹ College of Engineering, Mustansiriyah University, Baghdad, Iraq

² University College of Wisdom, Iraq

Contact person: Maaayed F. Al-Rawi, e-mail: maaayed@uomustansiriyah.edu.iq

ABSTRACT

Brain tumor segmentation aims to differentiate between various tumor tissues, including active cells, necrotic core, and edema, and normal brain tissues composed of cerebrospinal fluid (CSF), white matter (WM), and gray matter (GM). Over the last several years, studies that use magnetic resonance imaging (MRI) to segment brain tumors have garnered an increasing amount of interest. This is mostly due to the fact that MRI scans are non-invasive and provide an excellent contrast between soft tissue and bone. Computer-aided techniques for segmenting brain tumors are maturing and nearing integration into routine clinical applications. Researchers have developed these groundbreaking approaches over approximately twenty years. The objective of this article is to provide a K-means clustering technique for the purpose of brain tumor segmentation using magnetic resonance imaging (MRI). The K-means clustering technique is an unsupervised approach that is used for the purpose of separating the region of interest from the background. However, in order to increase the overall quality of the image, a partial stretching improvement is first done to the image before the K-means technique is implemented.

Keywords: MRI, image segmentation, cluster algorithm, brain tumor

For citation: Maaayed F. Al-Rawi, Muhanned AL-Rawi. Image Segmentation of Brain Tumors Using K-means Cluster Technique. Medical Radiology and Radiation Safety. 2026;71(2):107–114. DOI:10.33266/1024-6177-2026-71-2-107-114

1. Introduction

Any region of the body may develop a tumor, which is defined as the uncontrolled proliferation of cancer cells. Various types of tumors exhibit unique traits and require different treatment approaches. Nowadays, primary brain tumors and metastatic brain tumors categorize brain cancers. For the

former, the cancer starts in the brain and has a tendency to remain there, but for the latter, the disease starts in another part of the body and then spreads to the brain [1]. Benign and malignant brain tumors are two different types of brain tumors. In actuality, the most frequently utilized grading model is the one released by [2]. Under the microscope, it

¹ Maaayed F. Al-Rawi, ² Muhanned AL-Rawi

СЕГМЕНТАЦИЯ СНИМКОВ ОПУХОЛЕЙ ГОЛОВНОГО МОЗГА С ИСПОЛЬЗОВАНИЕМ КЛАСТЕРИЗАЦИИ МЕТОДОМ К-СРЕДНИХ

¹ Институт инженерии университета Мустансерия, Багдад, Ирак

² Колледж Университета Мудрости, Ирак

Контактное лицо: Maaayed F. Al-Rawi, e-mail: maaayed@uomustansiriyah.edu.iq

РЕЗЮМЕ

Сегментация изображений опухолей головного мозга направлена на дифференциацию различных компонентов опухолевых тканей, включая живые клетки, некротизированные ядра и области отека. Помимо этого, производится выделение нормальных тканей мозга: белого (БВ) и серого вещества (СВ), а также спинномозговой жидкости (СМЖ). За последние несколько лет благодаря неизвзавности и высокой контрастности получаемых изображений в значительной степени возрос интерес к исследованиям, описывающим сегментацию опухолей головного мозга на основе данных магнитно-резонансной томографии (МРТ). В течение последних двадцати лет компьютерные методы сегментации снимков опухолей головного мозга стремительно развивались и на сегодняшний день приближаются к интеграции в рутинную клиническую практику. Цель данной статьи – провести сегментацию МРТ-изображений опухоли головного мозга с использованием кластеризация методом К-средних. Кластеризация методом К-средних – это неконтролируемый подход, который используется для отделения области интереса от фона. В данной работе для повышения качества используемого МРТ-снимка было проведено его частичное растяжение.

Ключевые слова: МРТ, сегментация изображений, кластерный алгоритм, опухоль головного мозга

Для цитирования: Maaayed F. Al-Rawi, Muhanned AL-Rawi. Сегментация снимков опухолей головного мозга с использованием кластеризации методом К-средних // Медицинская радиология и радиационная безопасность. 2026. Т. 71. № 2. С. 107–114. (англ.). DOI:10.33266/1024-6177-2026-71-2-107-114

assigns grades 1 through 4 to the various types of brain tumors. A benign brain tumor is considered to be of low grade, whereas a malignant brain tumor is considered to be of high grade. Grade 1 and Grade 2 are examples of benign brain tumors. Most of the time, if a low-grade brain tumor is left untreated, it will eventually grow into a high-grade one. According to the 2021 Central Brain Tumor Registry of the United States (CBTRUS) Statistical Report, brain tumors are the second largest cause of cancer-related fatalities in children under the age of 18 and in men between the ages of 23 and 37 (leukemia being the top cause of death in this age range). It is the seventh highest cause of mortality from cancer in girls between the ages of 18 and 40. It was anticipated that there would be 72,832 new instances of primary brain tumors detected in 2022. These new cases would comprise both malignant (25,722) and non-malignant (54,220) brain tumors. An application of age-sex-race-specific incidence rates from the 2022 CBTRUS Statistical Report was used to predict corresponding age-sex-race groups on the basis of SEER and NPCR data [2]. This estimate was derived from the application of these rates. Consequently, brain tumors pose a significant threat to the lives of individuals, and because of this, early detection and treatment have become an absolute requirement [2].

The treatment methods for brain tumors involve chemotherapy, radiation therapy, and surgery. Other treatment options include radiation therapy. Imaging modalities, which have been developed in tandem with the advancement of medical imaging, play a big part in the assessment of patients who have brain tumors and have a substantial influence on the treatment that patients get. Recent years have witnessed the advancement of several sophisticated neuroimaging techniques, including X-rays, ultrasonography, CT,

MEG, EEG, PET, SPECT, and MRI. These modalities, when deployed in concert, furnish exceptionally clear and multidimensional views of brain tumors while simultaneously illuminating the underlying tumor biology, guiding the development of more directed and efficacious therapies. Clinicians play a pivotal role at every stage, and ensuring an accurate, timely diagnosis hinges on the delivery of a thoughtful, well-sequenced radiologic workup. Following a neurological finding of excellence, the radiologist must meticulously evaluate tumor location, volumetrics, and infratellar involvement, since this topographic intelligence calibrates the subsequent choreographic selections among chemotherapy, radiation, and operative interventions. Consequently, the sequencing and integration of these emergent imaging approaches have emerged as a central strategic challenge confronting radiology departments, necessitating the integration of multidisciplinary consensus and consensus-driven protocols. A noninvasive and effective tool for soft tissue contrast imaging, magnetic resonance imaging (MRI) offers valuable information about the location, size, and shape of brain cancers. This is done without subjecting the patient to high doses of ionization radiation. In the clinical area, the application of magnetic resonance imaging (MRI) for the diagnosis of brain tumors is increasing [3, 4].

Due to the vast volume of brain tumor images that are now being produced in clinics, it is not practical for doctors to manually annotate and segment these images in an acceptable period of time. Therefore, automated segmentation has become an unavoidable need. The process of segmenting a brain tumor involves separating aberrant tissues, such as the necrotic core, edema, and active cells from normal brain tissues, which include GM, WM, and CSF. In recent years, significant breakthroughs achieved in the area of brain

1. Введение

Опухоль есть суть продукт неконтролируемого разрастания раковых клеток, которое может произойти в любой части организма. Различные типы опухолей обладают уникальными свойствами и требуют специфических подходов к терапии.

В настоящее время рак головного мозга классифицируют на первичный и метастатический. В первом случае рак зарождается непосредственно в головном мозге и имеет тенденцию оставаться там же, а во втором же – заболевание развивается в другой области организма и затем распространяется на головной мозг [1]. Также опухоли головного мозга разделяют на злокачественные и доброкачественные. Наиболее часто используемая модель для их различения представлена в работе [2]. При микроскопическом исследовании опухолям головного мозга присваиваются степени злокачественности от 1 до 4, при этом степени злокачественности 1 и 2 означают доброкачественный характер новообразований, которые также обозначаются как низкоккачественные, тогда как злокачественные новообразования обозначаются как высококкачественные. В большинстве случаев, если низкоккачественную опухоль головного мозга не лечить, она со временем перерождается в высококкачественную. Согласно статистическому отчету Центрального реестра опухолей головного мозга США (CBTRUS) за 2021 г., опухоли головного мозга являются второй по распространенности причиной смертей от рака среди детей в возрасте до 18 лет и среди мужчин в возрасте от 23 до 37 лет (основной же причиной смертей от рака в этом возрастном диапазоне является лейкоз); это седьмая по частоте причина смертей, вызванных раком, у девушек в возрасте от 18 до 40 лет. Ожидалось, что в

2022 г. будет выявлено 72 832 новых случая первичных опухолей головного мозга как злокачественных (25 722), так и незлокачественных (54 220). При прогнозировании соответствующих групп на основе данных SEER и NPCR были использованы те же расовые, возрастные и половые критерии выборки, что и в статистическом отчете CBTRUS за 2022 г. [2]. Таким образом, опухоли головного мозга представляют значительную угрозу для жизни людей, и поэтому их раннее выявление и лечение стали весьма актуальной задачей [2].

Методы лечения опухолей головного мозга включают химиотерапию, лучевую терапию и хирургическое вмешательство. Различные методы визуализации играют важную роль в оценке состояния пациентов с опухолями головного мозга и оказывают существенное влияние на лечение, которое они получают. В последние годы наблюдается развитие ряда сложных методов нейровизуализации, включая рентгенографию, УЗИ, КТ, МЭГ, ЭЭГ, ПЭТ, ОФЭКТ и МРТ. Совместное применение этих методов позволяет получить исключительно четкую и многомерную картину опухоли головного мозга, одновременно выявляя ее биологию, что способствует применению более специфичных и эффективных методов лечения. Квалификация медицинского персонала играет ключевую роль на каждом этапе, так как именно врач определяет тактику обследования опухоли, что обеспечивает своевременность и точность диагностики, которая также зависит от врача-рентгенолога, который, свою очередь, будет проводить анализ полученных изображений опухоли, оценивая ее локализацию, размеры и степень поражения инфраселлярного пространства, что в последствии обусловит выбор методики лечения заболевания. Ввиду этого интеграция передовых методов

tumor segmentation have been achieved through the use of medical imaging and soft computing concepts. Brain tumor segmentation techniques readily identify the majority of aberrant brain tumor tissues. The issue of reliable and repeatable segmentation findings, as well as the representation of anomalies, remains unresolved [5].

Within the context of a decision-oriented application, image segmentation is one of the most frequently used approaches for accurately classifying the pixels that make up an image in a decision-oriented application. An image is partitioned into a set of disjoint regions so that pixels in the same region are very similar to each other and strong edges are likely to have boundaries that lie between regions. Many areas, such as medical image processing, traffic image recognition, pattern recognition, etc., can have tremendous applications using this technology. The image segmentation can be done by differential methods, threshold methods, edge, marker controlled, clustering, region growing, etc., activities of neural network. Clustering is one such technique which is believed to be one of the promising approaches from the various techniques. On the other hand, there are many distinct forms of clustering. These include the mountain clustering technique, the subtractive clustering approach, the K -means clustering method, and the fuzzy C -means clustering method. The k -means clustering method is one of the most used clustering techniques. It is easier to understand and more efficient in terms of computing than hierarchical clustering. In addition, it is possible to function for a huge number of variables. On the other hand, it does yield various cluster results depending on the number of clusters that are present. Therefore, it is necessary to set the correct number of clusters, denoted by k , as the starting value. It is necessary to initialize the k number of the centroid, as stated

previously. If the starting centroid had a different value, it would result in a different cluster. Therefore, choosing the appropriate starting centroid is another challenge that is of great importance. The process of extracting a region of interest from the backdrop is one of the most significant applications of image segmentation in the medical field, which has grown more essential in recent years. Consequently, medical images are segmented using a variety of techniques, and the outputs of the process are used for further research in the medical field. However, medical images in their raw form are represented by arrays of numbers on the computer [6]. The numbers indicate the values of key physical qualities that exhibit contrast between various kinds of body parts. In other words, the numbers reflect the raw form of the medical images. Processing and analysis of medical images are helpful in a number of ways, including the transformation of raw images into a measurable symbolic form, the extraction of significant qualitative information to assist in diagnosis, and the integration of complimentary data from various imaging modalities. Furthermore, one of the most important challenges in the field of medical analysis is the process of image segmentation, which is the process of determining the borders of objects in images, such as organs or aberrant regions. The results of the segmentation make it possible to do shape analysis, identify changes in volume, and construct an accurate radiation therapy treatment plan that is accurate [6].

2. Literature

Numerous studies have explored the segmentation of medical images using a variety of research approaches. Moreover, a great number of them are carried out using various applications of image segmentation. The K -means technique is the most straightforward clustering technique, and

визуализации требует внедрения и определенных протоколов, основанных на междисциплинарном консенсусе.

Неинвазивный и эффективный инструмент контрастной визуализации мягких тканей – магнитно-резонансная томография (МРТ) – дает ценную информацию о локализации, размере и форме опухолей головного мозга, при этом пациент не получает лучевую нагрузку. В клинической практике МРТ все чаще применяется для диагностики новообразований головного мозга [3, 4].

В связи с огромным количеством изображений опухолей головного мозга, которые в настоящее время получают в клиниках, становится необходимой автоматизация процессов аннотирования и сегментирования данных изображений с целью сохранения приемлемых сроков формирования врачебного заключения. Процесс сегментации опухоли головного мозга включает в себя отделение aberrantных тканей, таких как некротические ядра, области отека и активные клетки, от нормальных тканей мозга: БВ, СВ и СМЖ. В последние годы значительные прорывы в области сегментации опухолей головного мозга были достигнуты благодаря использованию методов радиомикки в медицинской визуализации. Современные методы сегментации опухолей головного мозга позволяют легко идентифицировать большинство aberrantных опухолевых тканей, однако вопросы надежности и воспроизводимости результатов сегментации, а также взаимодействия с аномалиями, остаются нерешенными [5].

Чаще всего, программы, предназначенные для анализа тех или иных изображений, производят объединение наиболее схожих между собой точек в отдельные области, границами между которыми являются, напротив, точки с наиболее резкими различиями; таким образом

исходное изображение разделяется на ряд непересекающихся областей. Данная технология может найти широкое применение в анализе снимков с дорожных камер, распознавании образов и обработке изображений в медицине. Сегментация изображений может быть выполнена дифференциальными методами, пороговыми методами, методами определения границ, маркерного контроля, выращивания областей и т. д. с широким применением нейронных сетей. Кластеризация – один из таких методов, к тому же весьма перспективный.

Существует множество различных форм кластеризации. К ним относятся метод горной кластеризации, метод субтрактивной кластеризации, кластеризация методом K -средних и нечеткая кластеризация методом C -средних. Кластеризация методом K -средних – одна из наиболее используемых стратегий кластеризации. Она проще для понимания и более эффективна с точки зрения объема и сложности вычислений, чем иерархическая кластеризация. Кроме того, она применима в работе с внушительным количеством переменных. С другой стороны, она даёт различные результаты кластеризации в зависимости от числа присутствующих кластеров. Поэтому в качестве начального значения необходимо задать их правильное количество, обозначаемое как k . Помимо этого необходимо инициализировать число k центроида, так как его различные значения приводят к формированию различных кластеров. Одним из наиболее важных процессов в сегментации медицинских снимков является отделение области интереса от фона, поэтому такие изображения сегментируются с использованием различных методов.

В контексте данного исследования необходимо помнить о том, что изображения содержатся в памяти компьютера в виде последовательности нулей и единиц,

there have been numerous distinct approaches done up to this point, each with its own unique approach to initializing the center.

There are also a great number of researchers that are working towards the development of new approaches that are more effective than the ways that are already in use and that provide better-segmented results. Discussed below are a few of the more recent works that have been published. A novel and effective method for the K -means clustering technique was presented in the article [6]. In order to generate the cluster center, they presented a novel approach that would reduce the mean square error of the final cluster without requiring a significant increase in the amount of time required for the execution. It decreased the inaccuracy in the means square without compromising the amount of time it took to execute. After doing a large number of comparisons, it is possible to draw the conclusion that the accuracy of dense datasets is higher than that of sparse datasets. Brain Tumor Segmentation Using K -means was the method that was suggested by the researchers in Reference [7]. A computation of the area of the clustering and fuzzy C -means techniques is shown here. In the paper, they divide the process into three separate steps: pre-processing the image comes first, then fuzzy c -means and advanced k -means, and lastly feature extraction. Prior to anything else, pre-processing is done by applying the filter in a way that improves the image's overall quality. After that, the advanced K -means technique that was presented is used, and then the fuzzy c -means technique is utilized to cluster the image. In the subsequent step, the segment image that was produced is used for the purpose of feature extraction for the area of interest. A magnetic resonance imaging (MRI) image was utilized for the study, and the size of the tumor

area that was isolated from the image was determined. An enhancement of the K -means clustering technique with an improved starting center was suggested in the article [8]. Presenting a new method for determining the initial centroid that provides a quick and effective way to assign the data points to suitable clusters while cutting down on the process's duration. In comparison to the original k -means clustering method, they demonstrated that their new technique achieves higher levels of accuracy while using minimal amounts of processing time. No further input, such as a threshold value, is required for this method to function properly. In spite of this, the method continues to initialize the number of clusters, denoted by k , and it has been proposed that the value of k be determined as one of the future works. Article [9] introduced an enhanced methodology to augment the precision and efficacy of the previously employed k -means clustering technique. They specifically offer a better version of the k -means technique that includes a systematic approach made up of two different methods. The first step is to find the original centroid. The second step is to put the data point into the clusters you have found. They looked at how long it took to run the system and how accurate it was with different starting centroid values. The results suggest that the proposed method was able to reduce the time complexity without affecting the accuracy of the clusters.

3. Technique of Clustering Based on K -Means

Clustering is a way to split a set of data into a set number of groups. K -means clustering is one of the most common ways to do things. K -means clustering is a method that splits a set of data into k groups, with 11 and 12 being the numbers in the group. It separates a set of data into k sepa-

которые в понятной, измеряемой форме описывают различия между точками, составляющими области изображения [6]. Таким образом машинная обработка медицинских изображений позволяет получить качественный, выраженный в конкретных числовых значениях, их анализ; помимо этого появляется возможность более тесной интеграции различных методов визуализации между собой. В конечном итоге все вышперечисленное позволяет сформировать максимально персонализированную стратегию лечения пациента [6].

2. Обзор литературы

На сегодняшний день существует довольно много исследований, посвященных сегментации медицинских изображений с применением широкого арсенала методик. Среди них выделяется кластеризация методом K -средних, в первую очередь, за счет своей простоты. В контексте данного метода представляет особый интерес процесс инициализации центроида: на данный момент существует множество уникальных подходов к решению этой задачи.

Также не стоит забывать и о новых, более эффективных, способах сегментации, в частности стоит отметить тактику кластеризации методом K -средних, описанную в статье [6]. В этом случае для генерации центра кластера авторы предложили новый подход, который позволил снизить среднеквадратичную ошибку итогового кластера без значительного увеличения времени выполнения вычислений. Помимо этого был проведен обширный сравнительный анализ, по итогам которого было установлено, что использование наборов плотных данных повышает точность вычислений, нежели использование наборов с разреженными данными.

Сегментация опухолей головного мозга с использованием метода K -средних описывалась и в другой работе [7], где также было рассмотрено применение метода нечетких C -средних. Процесс обработки изображения включал три этапа: на первом выполнялась предварительная обработка изображения с применением определенных фильтров, затем использовался расширенный метод K -средних, а после него-метод нечетких C -средних. На завершающем этапе производилось извлечение признаков из области интереса. Таким образом был определен размер новообразования на МРТ-снимке.

В статье [8] было предложено усовершенствование метода кластеризации K -средних с улучшенным начальным центроидом. Был представлен новый метод определения начального центра, который обеспечивает быстрое и эффективное распределение точек по подходящим кластерам, при этом сократилась длительность вычислений. Была отмечена более высокая точность нового подхода по сравнению с классической кластеризацией методом K -средних. Примечательно, что для корректной работы рассмотренного метода не требуется дополнительных исходных данных, таких как пороговое значение. Тем не менее, предлагаемый метод все также зависит от значения k , обуславливающего формирование различного числа кластеров, ввиду этого оптимальное значение k предлагается определить в дальнейших исследованиях.

В статье [9] была представлена усовершенствованная методология, направленная на повышение точности и эффективности ранее применявшейся кластеризации методом K -средних. В частности, авторы предлагают улучшенную версию метода K -средних, подразумевающую последовательное использование двух различных мето-

rate groups, each of which is different from the others. The K -means algorithm also has two parts that are different from each other.

The first stage computes the k initial centroids, with the next stage linking every individual point to the nearest one among these centroids according to the data point in question. Among the methods for measuring proximity, the Euclidean distance remains the most standard selection. The procedure then refreshes the centroid for each cluster, relying on the current point membership. From the updated centroids, new Euclidean distances are calculated between each centroid and every individual data point. Each point is reallocated to the cluster whose updated centroid minimises its distance. The entire cycle recommences, repeating the distance Assessment and reallocation until the point membership stabilises and no further assignments occur. The ultimate output includes all data points in each finalized cluster along with the updated centroids, clearly defining the clusters within the partition.

The point at which the total distances from all of the items that are included inside a cluster are at their shortest is often referred to as the centroid of that cluster. The K -means method is an iterative algorithm that reduces the sum of distances between each item and the centroid of its cluster, and it does this across all clusters to achieve this goal [10].

Let us take into consideration images that have a resolution of $x \times y$, given that the image has to be clustered into k different clusters. Cluster the input pixels as $p(x, y)$ with ck representing the centers of the clusters. The procedure for k -means clustering, as shown in reference [10], is as follows:

1. Initialize the number of clusters (k) and the center.
2. Using the relation $d = p(x, y) - ck$, calculate the Euclidean distance d between the center of an image and each

pixel of the image. This includes calculating the distance between each pixel and the center of the image.

3. Depending on the distance d , assign all of the pixels to the center that is closest to them.
4. Compute the new location of the center by using the provided relation $ck = 1/k \sum_{y \in ck} \sum_{x \in ck} p(x, y)$ after allocating all pixels.
5. It is necessary to repeat the operation until the tolerance or error value is satisfied once again. Apply a new shape to the cluster of pixels to create an image. Although k -means has the significant benefit of being simple to apply, it is not without complications.

It is not without its weaknesses. It depends on the arbitrary selection of the starting centroid to determine whether or not the ultimate clustering findings are of high quality. The initial centroid is chosen at random. Each original center will experience a distinct outcome when selected. Due to that, the center will be selected with great care in order to achieve the segmentation that we seek. Furthermore, computational complexity is an additional aspect that we need to take into consideration while building the K -means clustering algorithm. The quantity of data items, the number of clusters, and the number of iterations all work together to determine its success.

4. Results and discussion

The MRI scan of the brain collects images, yielding grayscale images as output. A grayscale image is a data matrix whose values indicate different shades of gray. A numeric value or an intensity value that falls within the range (0–255) is assigned to each member of the grayscale matrix. Digital images acquired from magnetic resonance imaging (MRI) are stored in MATLAB in matrix form for the purpose of ap-

дик. На первом этапе работы предлагается установить исходный центроид, а на втором – разместить анализируемые точки в сформированные кластеры. По результатам тестирования с различными начальными центроидами установлено, что данный подход обеспечивает экономию времени без снижения точности кластеризации.

3. Метод кластеризации на основе K -средних

Кластеризация – это способ разбиения набора данных на заданное количество групп, а кластеризация методом k -средних – один из наиболее распространенных ее способов: в этом случае происходит разделение набора данных на k -количество различных групп, где 11 и 12 – числа в группе. Алгоритм k -средних состоит из двух частей: на первом этапе вычисляются число k начальных центров, а на втором – каждая отдельная точка включается в кластер с наиболее схожими точками. Затем производится обновление центроида для каждого кластера на основе среднего арифметического входящих в кластер точек. Чаще всего схожесть точек определяется на основе евклидова расстояния, при этом после каждого обновления центроида эти расстояния рассчитываются заново между каждым новым центром и каждой точкой. Изменение значения схожести – евклидова расстояния – приводит к последующему перераспределению точек между кластерами. Эти процессы продолжают до момента т.н. стабилизации принадлежности. В конечном итоге все точки оказываются в четко разделенных между собой кластерах с обновленными центроидами.

Центроид кластера – это точка, для которой сумма расстояний до всех элементов, включенных в кластер достигает своего минимума. Метод k -средних – это итерационный алгоритм, который уменьшает сумму

расстояний между каждым элементом и центроидом его кластера [10].

Рассмотрим пример распределения изображения с разрешением $x \times y$ в k различных кластерах. Кластеризуем входные пиксели как $p(x, y)$, где ck представляет центры кластеров. Процедура кластеризации методом k -средних, как показано в [10], выглядит следующим образом:

1. Инициализация количества кластеров (k) и центроида.
2. Вычисление евклидова расстояния d между центром кластера и каждым пикселем изображения с использованием $d = p(x, y) - ck$.
3. В зависимости от расстояния d производится внесение пиксела в кластер с наиболее близким центроидом.
4. После распределения всех пикселей производится вычисление нового положения центра с применением следующего соотношения: $ck = 1/k \sum_{y \in ck} \sum_{x \in ck} p(x, y)$.
5. П.4 повторяется до тех пор, пока не будет достигнуто значение допуска (ошибки).

Несмотря на свою простоту, алгоритм k -средних имеет ряд недостатков. Качество окончательного результата кластеризации определяется произвольным выбором начального центроида, т.е. использование разных начальных центров приведет к формированию различных результатов. Ввиду этого для достижения желаемых результатов сегментации изображения следует с особой тщательностью выбирать стартовый центроид. Также следует обратить внимание на то, что использование алгоритма k -средних требует выполнения целого ряда сложных вычислений. Таким образом, количество элементов данных, количество кластеров и количество

plying various algorithms. During the experimental results, Fig. 1 shows the K -means clustered image, and Fig. 2 shows the extracted edges as shown below:

Also, Figs. 3 and 4 reveal extracted gray matter and intensity adjusted gray matter, respectively.

And not lastly, Fig. 5 and 6 depicted below show extracted white matter and intensity adjusted white matter.

5. Conclusion

This study used the k -clustering technique to segment an image, and the initial centroid was obtained using the subtractive cluster. Applying partial contrast stretching enhances the quality of the original image, while utilizing the median filter improves the segmented image. It is also possible to customize the output images by adjusting the radius of the hypersphere cluster, and we may draw a conclusion from this




Fig. 1. Shows K -means clustered image
Рис. 1. Кластеризированный снимок,




Fig. 2. Shows extracted edges
Рис. 2. Выделенные границы между областями методом K -средних




Fig. 3. Shows extracted gray matter
Рис. 3. Выделенное серое вещество




Fig. 4. Shows intensity adjusted gray matter
Рис. 4. Выделенное серое вещество с корректировкой на интенсивность сигнала

итераций – всё это вместе определяет успешность применения алгоритма.

4. Результаты и их обсуждение

МРТ головного мозга позволяет получать изображения в оттенках серого, которые представляют собой матрицу данных, значения которой соответствуют различным оттенкам цвета. Каждому элементу матрицы присваивается числовое значение оптической плотности в диапазоне (0–255). Цифровые изображения, полученные с помощью магнитно-резонансной томографии (МРТ), сохраняются в программе MATLAB в матричной форме с целью дальнейшего применения к ним ряда различных алгоритмов. На рис. 1 показано изображение, кластеризованное в процессе данного исследования по методу K -средних, а на рис. 2 продемонстрированы выделенные границы между различными зонами снимка.

На рис. 3 представлено выделенное серое вещество, на рис. 4 показано то же самое, но с поправкой на интенсивность сигнала:

На рис. 5 показано выделенное белое вещество, на рис. 6 показано то же самое, но с поправкой на интенсивность сигнала:

Наконец, на рис. 7 представлена выделенная опухоль на начальной стадии развития.

5. Заключение

В данном исследовании была произведена сегментация изображения с использованием метода k -кластеризации, начальный центроид для которого был определен с помощью разностного кластера.

Применение частичного растяжения контраста улучшает качество исходного снимка, а использование медианного фильтра улучшает сегментированное изображение. Также возможно изменять итоговый результат путем варьирования радиуса кластера гиперсфер. Все эти приемы применяются одновременно. Предлагаемый в данной статье вариант кластеризации k -средних обладает рядом преимуществ над классическим алгоритмом k -средних, а именно допустимостью

finding that by adjusting the radius of the hypersphere cluster, we can get varied output. These techniques are executed concurrently. When the final segmented result is compared with the k -means clustering method, we are able to draw the conclusion that the suggested clustering technique has superior segmentation, which means the root mean square error

(RMSE) and the peak signal-to-noise ratio (PSNR) are small and big values, respectively, for the proposed technique. The proposed technique outperforms the traditional K -means algorithm in terms of RMSE and PSNR, as these values are the criteria for a decent image.



Fig. 5. Shows extracted white matter
Рис. 5. Выделенное белое вещество




Fig. 6. intensity adjusted white matter
Рис. 6. Выделенное белое вещество с корректировкой на интенсивность сигнала




Fig. 7. Shows segmented tumor as an initial stage
Рис. 7. Выделенная опухоль на начальной стадии развития

как малых, так и больших значений среднеквадратической ошибки (RMSE) и пикового отношения сигнал/шум (PSNR) соответственно. Данный результат был подтвержден при оценке итогового результата сегмен-

тации. Стоит отметить, что показатели RMSE и PSNR оказывают значительное влияние на результаты работы классического метода k -средних.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Muaayed F. Al-Rawi, Izz K. Abboud, Nasir A. Al-Awad. Using Machine Learning Algorithms to Detect Cancer Automatically. *Medical Radiology and Radiation Safety*. 2025;70;3:83-89.
2. URL: <https://www.who.int/>.
3. Izz K. Abboud, Muaayed F. Al-Aawi, Nasir A. Al-Awad. Digital Medical Image Encryption Approach in Real-Time Applications. *System Research & Information Technologies*. 2024;1:26-32.
4. Muaayed F. Al-Rawi, Izz K. Abboud, Nasir A. Al-Awad. Novel Approach Using Transfer Deep Learning for Brain Tumor Prediction. *Medical Radiology and Radiation Safety*. 2021;69;3:81-85.
5. Lotlikar V.S., Satpute N., Gupta A. Brain Tumor Detection Using Machine Learning and Deep Learning: A Review. *Current Medical Imaging*. 2022;18;6:1-19.
6. Kovesi B., Boucher J.M., Saudi S. Stochastic K-means Algorithm for Vector Quantization. *Pattern Recognition Letters*. 2001;22:603-610.
7. Gdalyahu Y., Weinsall D., Wermen M. Self-Organization in Vision: Stochastic Clustering for Image Segmentation, Perceptual Grouping, and Image Database Organization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2016;23;12:1053-1074.

8. Veenman C.J., Reinders M.J.T., Backer E. A Maximum Variance Cluster Algorithm”, IEEE Transactions on Pattern Analysis and Machine Intelligence. 2018;24;9:1273-1280.
9. Carson C., Greenspan H. Blobworld: Image Segmentation Using Expectation-Maximization and Its Application to Image Querying. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2018;24;8:1026-1038.
10. Atsushi K., Masayuki N., Means K. Algorithm Using Texture Directionality for Natural Image Segmentation. IEICE Technical Report. Image Engineering. 2019;97;8:17-22.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.
Финансирование. Исследование не имело спонсорской поддержки.
Участие авторов. Статья подготовлена с равным участием авторов.
Поступила: 20.01.2026. Принята к публикации: 25.02.2026.

Conflict of interest. The authors declare no conflict of interest.
Financing. The study had no sponsorship.
Contribution. Article was prepared with equal participation of the authors.
Article received: 20.01.2026. Accepted for publication: 25.02.2026.