

УДК 004.93

# Нечеткая сегментация слабоконтрастных радиологических изображений

**А. М. Ахметшин, Л. Г. Ахметшина**

Днепропетровский национальный университет, Украина

## Резюме

Описан метод сегментации слабоконтрастных изображений на основе их нечеткой интерпретации. В рамках метода один участок анализируемого изображения может быть соотнесен с несколькими кластерами и решение о его конкретной принадлежности принимается на основе анализа особенностей функции принадлежности. Представлены экспериментальные результаты демонстрирующие информационные возможности метода.

**Ключевые слова:** сегментация, нечеткая кластеризация, чувствительность, низкий контраст.

**Клин. информат. и Телемед.**  
2010. Т.6. Вып.7. с.37–42

## Введение

Основные методы цифровой обработки изображений различной физической природы (условно их можно назвать «классическими») обобщены в работах [1, 2]. Однако следует признать, что применение этих методов для анализа медицинских изображений во многих случаях является не эффективным (примеры приведены ниже). По нашему мнению, это обуславливается как особенностями формирующих систем (анизотропность, отсутствие информации об их характеристиках) и яркостных характеристик получаемых изображений, многие из которых являются слабоконтрастными, так и отсутствием во многих случаях априорных данных о наличии и расположении объекта интереса (аномалий).

В этой связи, одной из основных и наиболее сложных в теории и практике анализа слабоконтрастных медицинских изображений является задача кластеризации и сегментации, решение которой позволяет идентифицировать объект интереса и сформулировать направление дальнейшего исследования. В данном случае сегментация изображения может быть интерпретироваться как результат визуализации результатов кластерного анализа [5]. Трудности выполнения этого этапа во многом связаны с неоднозначностью присутствующей в исходных данных, которая имеет объективный характер. Кроме факторов случайности, которые описываются теорией вероятности, следует выделить три других вида неопределенности: двусмысленность интерпретации градаций серого (результат дискретизации, анизотропности систем фор-

мирования, и т. д.), геометрическую нечеткость (объективная неопределенность границ, например, между здоровой и перерожденной тканью; различного типа искажения), нечеткость априорных знаний (например, качества пленки при формировании исходного изображения). Эти факторы, естественно, приводят к наличию неопределенности или нечеткости в обработанных изображениях, что влияет на достоверность результатов их интерпретации.

Учет этих факторов можно реализовать только в рамках нечеткого подхода, фундаментом которого является математический аппарат нечеткой логики [3]. Данное направление интенсивно развивается в настоящее время как одна из основных частей общей методологии теории и практики искусственного (вычислительного) интеллекта [4].

В этой связи следует отметить, что классические методы цифровой обработки изображений и указанное новое направление, развиваются как бы независимо друг от друга. Так в [1, 2] отсутствует малейшее упоминание об информационных возможностях аппарата нечеткой логики, что, по нашему мнению, ограничивает возможности решения прикладных задач.

## Цель работы

Целью данной работы является демонстрация информативных возможностей метода нечеткой сегментации медицинских изображений в сопоставлении с известными методами их цифровой обработки.

## Материалы и методы исследования

### Алгоритм нечеткой кластеризации

Концептуальная взаимосвязь между кластеризацией и теорией нечетких множеств основана на том, что при структуризации сложных образов необходимо учитывать тот факт, что существует множество реальных объектов, не имеющих четких границ по своей природе. Требование необходимости обеспечения однозначности при кластеризации

нечетких данных в таком случае является неадекватным, особенно при необходимости учета незначительных различий или для кластеров сложной формы, перекрывающихся между собой (например, раковая опухоль с метастазами).

В основе классических (четких) методов кластеризации лежит определение значений (центроид), характеризующих каждый кластер в заданном признаковом пространстве и отнесение объекта к классу, на основе некоторой меры, обычно расстояния в пространстве признаков. На рис. 1а представлены два кластера с центроидами  $v_1, v_2$ . В данном примере, точка В, принадлежащая кластеру 2 находится на одинаковом расстоянии от обоих центров, что затрудняет ее кластеризацию; точка А, принадлежащая кластеру 2, находится ближе к центру кластера 1, что приведет

к ложной кластеризации; принадлежность точки С вообще нельзя определить однозначно, так как она находится на границе классов. На рис 1б приведено изображение раковой опухоли печени (темные участки в центре), которое соответствует именно такому случаю.

Нечеткая или мягкая кластеризация вводит понятие нечетких кластеров и функцию принадлежности объектов к ним, изменяющуюся в интервале  $[0;1]$ , что позволяет оценить степень принадлежности объекта к тому либо иному классу. На рис. 2а приведены функции распределения, соответствующие объектам, относящимся двум различным классам, а на рис. 2б приведена гистограмма рис. 1б, демонстрирующая отсутствие четкого разграничения между опухолью и нормальной тканью.

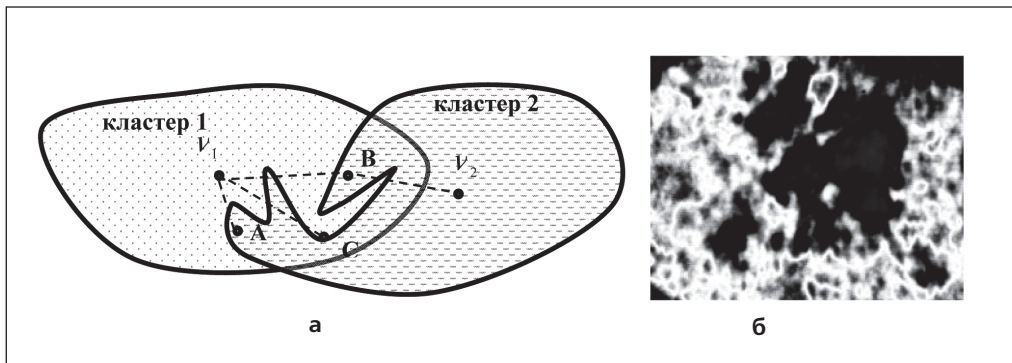


Рис. 1. Два кластера со сложной конфигурацией: а — неоднозначность определения принадлежности точек к кластеру; б — медицинское радиологическое изображение.

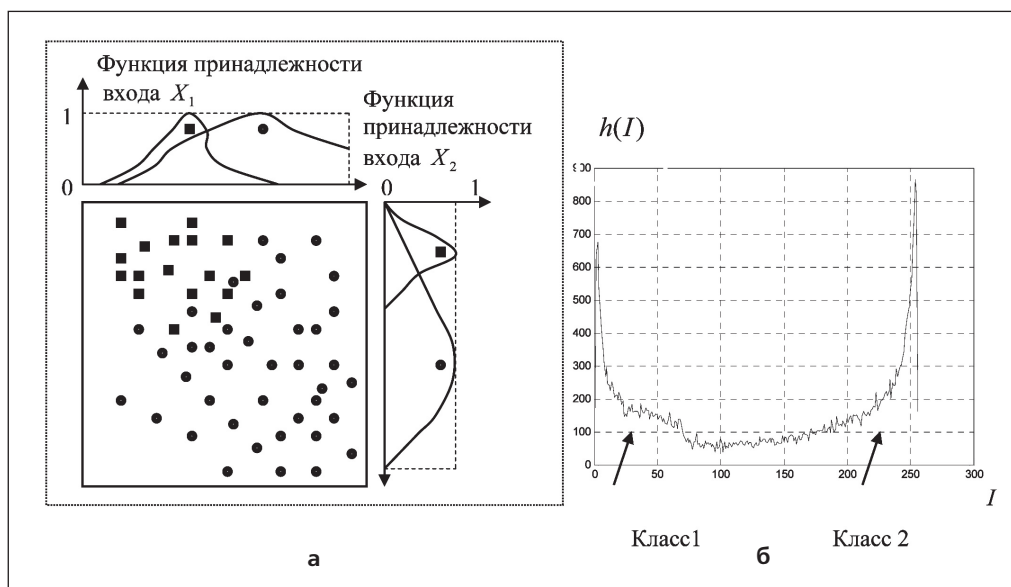


Рис. 2. а — Распределение данных и соответствующие функции принадлежности для двумерного входного вектора (а); б — гистограмма распределения яркостей рис. 1б.

Первым методом нечеткой кластеризации был метод нечетких  $C$ -средних (Fuzzy  $C$ -means – FCM) [3, 6], имеющий в настоящее время множество модификаций. Метод FCM базируется на использовании идей и математического аппарата нечеткой логики. Первый пример использования этого метода для сегментации многопараметровых изображений ЯМР-томографии был описан в работе [7]. В ходе работы алгоритма FCM каждому пикселю изображения ставится в соответствие вектор из функций принадлежности к каждому классу, на основе которого можно делать выводы о природе данного объекта.

Задача нечеткой кластеризации формулируется следующим образом: на основе исходных данных  $D$  определить такое нечеткое разбиение  $\mathfrak{X}(A) = \{A_k | A_k \subseteq A\}$  или нечеткое покрытие  $\mathfrak{S}(A) = \{A_k | A_k \subseteq A\}$  множества  $A$  на заданное число  $c$  нечетких кластеров  $A_k (k \in \{2, \dots, c\})$ , которое доставляет экстремум некоторой целевой функции  $f(\mathfrak{X}(A))$  среди всех нечетких разбиений или экстремум целевой функции  $f(\mathfrak{S}(A))$  среди всех нечетких покрытий.

Для уточнения вида целевой функции  $f(\mathfrak{S}(A))$  в рассмотрение вводятся некоторые дополнительные понятия. Прежде всего, предполагается, что искомые нечеткие кластера представляют собой нечеткие множества  $A_k$ , образующие нечеткое покрытие исходного множества объектов кластеризации  $A$ , для которого имеет место следующие соотношение:

$$\sum_{K=1}^c u_{A_k}(a_i) = 1 (\forall a_i \in A), \quad (1)$$

где  $C > 1$  – общее количество нечетких кластеров  $A_k (k \in \{2, \dots, C\})$ , которое считается предварительно заданным.

Алгоритм базируется на использовании процедуры итеративной минимизации целевой функции вида [3]

$$J(U, V) = \sum_{i=1}^c \sum_{n=1}^N u_{in}^m |x_n - v_i|^2, \quad (2)$$

где  $V = \{v_1, \dots, v_c\}$  – центры кластеров;  $U = [u_{in}]$  – матрица размером  $C \times N$ , где  $u_{in}$  есть  $i$ -я функция принадлежности  $n$ -го входа  $x_n, m \in [1, \infty)$  – параметр фаззификации или экспоненциальный вес.

Значение показателя  $c$  степени  $m$ , который называется параметром фаззификации или экспоненциальным весом выражает степень нечеткости функции принадлежности. Чем  $m$  больше, тем конечная матрица  $C$ -разбиения становится более «размытой», и при  $m \rightarrow \infty$  она примет вид  $1/c$ , т. е. все объекты

принадлежат ко всем кластерам с одной и той же степенью (что является очень плохим решением). При  $m = 1$  кластеризация становится четкой. Экспоненциальный вес позволяет при формировании координат центров кластеров усилить влияние объектов с большими значениями степеней принадлежности и уменьшить влияние объектов с малыми значениями степеней принадлежности. На сегодня не существует теоретически обоснованного правила выбора значения этого параметра, лишь эмпирическое правило, говорящее о том, что с увеличением количества элементов множества классифицируемых объектов значение  $m$  уменьшается.

Значения функций принадлежности должны удовлетворять следующим ограничениям

$$0 \leq u_{in} \leq 1, i = 1, 2, \dots, C; n = 1, 2, \dots, N; \quad (3)$$

$$\sum_{i=1}^c u_{in} = 1, n = 1, 2, \dots, N; \quad (4)$$

$$0 < \sum_{n=1}^N u_{in} < N, n = 1, 2, \dots, C. \quad (5)$$

Алгоритм является итеративным и основан на последовательном вычислении следующих уравнений:

$$v_i = \frac{1}{\sum_{n=1}^N u_{in}^m} \sum_{n=1}^N u_{in}^m x_n; i = 1, 2, \dots, C; \quad (6)$$

$$u_{in} = \frac{\left| \frac{1}{|x_n - v_i|^2} \right|^{1/(m-1)}}{\sum_{j=1}^c \left| \frac{1}{|x_n - v_j|^2} \right|^{1/(m-1)}}; \quad (7)$$

$$i = 1, 2, \dots, C; n = 1, 2, \dots, N.$$

Для каждого входного вектора значение функции принадлежности к каждому кластеру зависит от расстояния до соответствующего центра кластера.

Алгоритм FCM состоит из следующих шагов:

1. Инициализация числа кластеров  $c$ , значения  $m$ , начальных значений функции принадлежности  $u$ .

2. Вычисление значений центров нечетких кластеров:

$$u_{in} = \frac{\sum_{i=1}^n (u_{ki})^m \cdot x_{ij}}{\sum_{i=1}^n (u_{ki})^m}, \left( \begin{array}{l} \forall k \in \{2, \dots, C\}, \\ \forall j \in \{1, \dots, q\} \end{array} \right), \quad (8)$$

где  $n$  – число объектов кластеризации;  $q$  – количество информативных признаков, описывающих каждый экземпляр данных  $x_{ij}$ .

3. Вычисление текущего значения целевой функции  $f_t$ :

$$f_t = \sum_{i=1}^n \sum_{k=1}^c (u_{ki})^m \sum_{j=1}^q (x_{ij} - v_{kj})^2 \quad (9)$$

4. Вычисление текущих значений функции принадлежности  $u$ :

$$u_{in} = \left[ \frac{\left( \sum_{j=1}^q (x_{ij} - v_{kj})^2 \right)^{1/2}}{\left( \sum_{j=1}^q (x_{ij} - v_{kj})^2 \right)^{1/2}} \right]^{-1}, \quad (10)$$

$$\left( \begin{array}{l} \forall k \in \{2, \dots, C\}, \\ \forall i \in \{1, \dots, n\} \end{array} \right),$$

5. Если разность целевых функций текущего и предыдущего шагов


$$|f_t - f_{t-1}| > \varepsilon, \quad (11)$$

где  $\varepsilon$  – пороговое значение, то переход к пункту 2.


К достоинствам алгоритма нечетких  $C$ -средних можно отнести его гибкость и возможность работы непосредственно со значениями функций принадлежности. К недостаткам FCM следует отнести необходимость априорного задания числа кластеров  $c$ , что диктует необходимость проведения ряда экспериментов по сегментации анализируемого изображения при различных значениях  $c$ .

## Экспериментальные результаты

На рис. За представлено изображение рентгеновской томограммы головного мозга после введения контрастного вещества. Особенностью данного изображения является тот обстоятельство, что исходная гематома хорошо видна (указана стрелкой), однако область ее «скрытого» влияния, даже после введения контрастного вещества, является плохо различимой. Применение широко распространенных методов эквализации гистограмм (рис. 3б) и метода градиентного отображения (рис. 3в) [1]



**Рис. 3.** Рентгеновская томограмма гематомы головного мозга: а — оригинал; б — результат применения метода эквализации гистограмм; в — модуль градиентного отображения анализируемого изображения.



**Рис. 4.** Гистограммы распределения яркостей: а — исходного изображения (рис. 3а); б — эквализованного изображения (рис. 3б).

не обеспечивает повышения чувствительности и достоверности визуального анализа изображения. Применение метода градиентного отображения не дает требуемого результата в связи с тем, что его использование эффективно при сегментации слабоконтрастных участков, расположенных на однородном, или плавно изменяющимся яркостном фоне [8], что в данном случае не выполняется.

Отсутствие успеха при применении метода эквализации гистограмм требует более детального анализа, поскольку в [1, 2] отсутствуют методические указания об условиях применимости данного

метода. Как показали результаты наших экспериментальных исследований, метод эквализации гистограмм является эффективным лишь в том случае, когда гистограмма распределения яркостей исходного изображения не занимает весь диапазон.

На рис. 4а представлена гистограмма яркости исходного (рис. 3а), а на рис. 4б гистограмма эквализованного (рис. 3б) изображений. Из рассмотрения рис. 3а следует, что исходная гистограмма занимает полный диапазон яркостей, что и обуславливает неэффективность применения метода эквализации гистограмм.

На рис. 5 представлены результаты сегментации томограммы методом нечетких  $S$ -средних для различного числа кластеров. Из его рассмотрения видно, что задача сегментации информативного участка достигается уже при количестве кластеров  $c = 4$  (рис. 5а), однако более удовлетворительный результат обеспечивается при  $c = 6$  (рис. 5б). Дальнейшее увеличение числа кластеров, приводящее к существенному увеличению машинного времени вычислений, по нашему мнению, является нецелесообразным (рис. 5в).

На рис. 6а представлена томограмма опухоли головного мозга. Применение




Рис. 5. Результаты нечеткой сегментации изображения на рис. За при выборе различного числа кластеров: а — ( $C=3$ ); б — ( $C=6$ ); в — ( $C=12$ ).

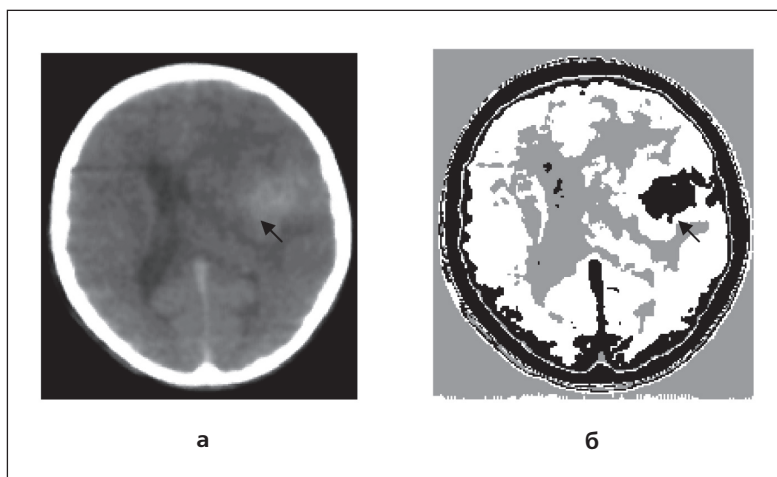


Рис. 6. Рентгеновская томограмма скрытой опухоли головного мозга: а — оригинал; б — результат нечеткой сегментации ( $C=3$ )

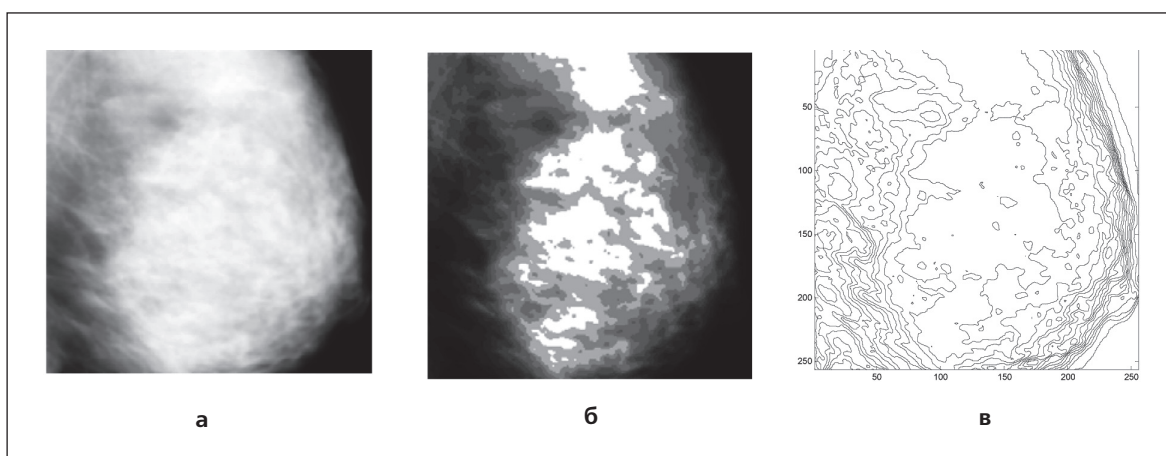


Рис. 7. Маммографическое изображение: а — оригинал; б — результат нечеткой сегментации ( $C=12$ ); в — отображение анализируемого изображения на основе построения равноудаленных линий уровня яркости ( $L=12$ ).

метода нечеткой сегментации (рис. 6б) позволило выделить патологический участок при минимальном выборе числа кластеров ( $c=6$ ).

На рис. 7а представлено изображение маммограммы, представляющее собой классический образец слабо-контрастного и весьма неоднородного (в яркостном отношении) изображения. С учетом последнего обстоятельства, в данном случае для повышения детальности визуального анализа целесообразен выбор большего числа кластеров. Оптимальным оказалось значение  $c=12$  (рис. 7б). Интересным в данном случае является то обстоятельство, что анализ исходного изображения на основе построения равноудаленных линий яркости (рис. 7в) (число которых  $L=12$ , равно числу кластеров, не приводит к идентичным результатам), т.е. применение метода нечеткой сегментации оказалось более эффективным по сравнению с использованием еще одного распространенного метода анализа слабоконтрастных изображений.

## Заключение

1. Нечеткая сегментация слабоконтрастных изображений является полезным и эффективным дополнением к существующим методам цифровой обработки изображений в ситуациях, когда последние не позволяют выделить контуры потенциально информативных участков.

2. Особенностью нечеткой сегментации является необходимость априорного задания числа кластеров, что обуславливает необходимость проведения ряда экспериментов с варьируемым числом кластеров.

## Литература

1. Гонсалес Р. Цифровая обработка изображений / Гонсалес Р., Вудс Р.; [пер. с англ. под ред. П. А. Чочиа]. – М.: Техносфера, 2006. – 1070 с.
2. Яне Б. Цифровая обработка изображений / Яне Б.; [пер. с англ. Измайловой А. М.]. – М.: Техносфера, 2007. – 583 с.
3. Chi Z. Fuzzy algorithms: With Applications to Image Processing and Pattern Recognition / Chi Z., Yan H., Pham T. – Singapore; – New Jersey; – London; – Hong Kong: Word Scientific, 1998. – 225 p.
4. Mann S. Intelligent Image Processing / Mann S. – N.Y.: John Wiley and Sons Inc, 2002. – 342 p.
5. Форсайт Д., Понс Ж. Компьютерное зрение: современный подход / Форсайт Д., Понс Ж.; [пер. с англ. А.В. Назаренко, И. Ю. Дорошенко]. – М.; – С.-П.: Вильямс, 2004. – 926 с.
6. Леоненков А. Нечеткое моделирование в среде MATLAB и fuzzyTECH / Леоненков А. – С.П.: БХВ-Петербург, 2003. – 719 с.
7. Hall L. O. A comparison of neural network and fuzzy clustering techniques in segmentation MRI of the brain / Hall L.O., Bensaid A., Clarke L.P. Velthuisen R.P. [et. al.] // IEEE Trans. on Neural Networks. – 1992. – Vol. 3. – P. 672–682.
8. Ахметшина Л. Г. Выделение скрытых областей изображений методом модуляционного градиентно-фазового преобразования / Ахметшина Л. Г., Мацюк И. М. // Системні технології. . – Дніпропетровськ, 2009. – Вип. 1 (60). – С. 29–35.

## Переписка

д. физ.-мат. наук  
профессор **А. М. Ахметшин**  
Днепропетровский национальный университет  
пр. Гагарина 72.  
Днепропетровск, 49000, Украина  
эл. почта: akhmlu@mail.ru

## Fuzzy segmentation of low contrast radiological images

A. M. Akhmetshin, L. G. Akhmetshina  
Dnepropetrovsk National University  
Ukraine

### Abstract

A method of low contrast radiological images segmentation on base using of its fuzzy interpretation is outlined. In the network of this method one part analyzed image can be correlated with same clusters and solution about of ones concrete belongings accepted on base analysis its membership function. Experimental results information possibilities of the method are presented.

**Key words:** segmentation, fuzzy clustering, sensitivity, low contrast.

## Нечітка сегментація низькоконтрастних радіологічних зображень

О. М. Ахметшин, Л. Г. Ахметшина  
Дніпропетрівський національний університет, Україна

### Резюме

Описано новий метод сегментації низько-контрастних радіологічних зображень на підставі використання їх нечіткої інтерпретації. В рамках методу одна ділянка аналізованого зображення може бути порівнювана з кількома кластерами і рішення о його конкретній належності приймається на підставі аналізу особливостей його функції належності. Представлені експериментальні результати демонструють інформаційні можливості методу.

**Ключові слова:** сегментація, нечітка кластеризація, чутливість, низький контраст.