

## Применение модели скоростной кластеризации пикселей в задачах предобработки изображений дистанционного зондирования Земли

И. Г. Ханьков <sup>1</sup> ✉

<sup>1</sup> Санкт-Петербургский Институт информатики и автоматизации Российской академии наук (СПИИРАН)  
14 линия В.О. 39, г. Санкт-Петербург 199178, Российская Федерация

✉ e-mail: [igk@iias.spb.su](mailto:igk@iias.spb.su)

### Резюме

**Цель исследования** заключается в применении модифицированного метода Уорда в скоростной обработке полноразмерных изображений дистанционного зондирования Земли.

**Методы.** Классический метод Уорда модифицируется путем разделения вычислительного процесса на три последовательных этапа. На первом этапе строится грубая иерархия приближений. На втором этапе выполняется промежуточное улучшение качества заданного разбиения при фиксированном числе цветов. Третий этап кластеризует полученные суперпиксели классическим методом Уорда. Программно-алгоритмический инструментарий составляют четыре операции над кластерами пикселей и сегментами изображения: слияние пары кластеров в один, разделение кластера на два исходных, выделение подмножества пикселей в отдельный кластер и реклассификация части пикселей путем исключения из одного кластера и отнесения их в другой. Оценкой качества служит суммарная квадратичная ошибка. Улучшение качества разбиения изображения обеспечивается итеративным исполнением сочетания операций слияния и разделения кластеров пикселей, в частности сегментов изображения. Один из кластеров (сегментов) разделяется надвое и пара других несовпадающих с ним объединяется в один по критерию минимального приращения суммарной квадратичной ошибки.

**Результаты.** Предложенный модифицированный метод Уорда применен в обработке полноразмерных изображений дистанционного зондирования Земли, взятых из базы данных Института обработки сигналов и изображений Южно-Калифорнийского университета. Сопоставлены результаты обработки в режимах чистой сегментации и кластеризации.

**Заключение.** Предложенная модель кластеризации пикселей пригодна для скоростной обработки полноразмерных изображений. Кластеризация пикселей по сравнению с сегментацией изображений позволяет более детально определить как контуры объектов интереса, так и их внутреннюю структуру.

---

**Ключевые слова:** сегментация изображений; кластеризация пикселей; скоростная кластеризация; суперпиксели, иерархия приближений.

**Конфликт интересов:** Автор декларирует отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

**Для цитирования:** Ханьков И. Г. Применение модели скоростной кластеризации пикселей в задачах предобработки изображений дистанционного зондирования Земли // Известия Юго-Западного государственного университета. 2020; 24(2): 90-107. <https://doi.org/10.21869/2223-1560-2020-24-2-90-107>.

Поступила в редакцию 30.10.2019

Подписана в печать 06.02.2020

Опубликована 20.04.2020

## Application of the Pixel Velocity Clustering Model in the Tasks of Preprocessing images of Earth Remote Sensing

Igor G. Khanykov <sup>1</sup> ✉

<sup>1</sup> St.Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences (SPIIRAS)  
39, 14-th Line V.O., St. Petersburg 199178, Russian Federation

✉ e-mail: [igk@iiias.spb.s](mailto:igk@iiias.spb.s)

### Abstract

**Purpose of research** is to apply the modified Ward method in high-speed processing of full-size images of Earth remote sensing.

**Methods.** The classical Ward method is modified by dividing the computational process into three successive stages. At the first stage, a rough hierarchy of approximations is built. At the second stage, an intermediate improvement of the quality of the given partition is performed for a fixed number of colours. At the third stage, the obtained superpixels are clustered using the classical Ward method. The software-algorithmic toolkit consists of four operations on pixel clusters and image segments: merging a pair of clusters into one, dividing a cluster into two original ones, singling out a subset of pixels into a separate cluster and reclassifying some pixels by excluding them from one cluster and assigning them to another. The quality is assessed by the total squared error. Improving the image decomposition quality is ensured by iterative execution of a combination of merging and dividing pixel clusters, image segments, in particular. One of the clusters (segments) is divided in two and a couple of others non-coincident with it are combined into one according to the criterion of minimum increment of the total squared error.

**Results.** The proposed modified Ward method is applied in the processing of full-size images of Earth remote sensing taken from the database of the USC Signal and Image Processing Institute. The results of processing in the modes of pure segmentation and clustering are compared.

**Conclusion.** The proposed pixel clustering model is suitable for high-speed processing of full-size images. Pixel clustering in comparison with image segmentation makes it possible to define in more detail both the contours of objects of interest and their internal structure.

**Keywords:** image segmentation; pixel clusterization; high-speed clustering; superpixels, hierarchy of approximations.

**Conflict of interest.** The author declare the absence of obvious and potential conflicts of interest related to the publication of this article.

**For citation:** Khanykov I. G. Application of the Pixel Velocity Clustering Model in the Tasks of Preprocessing images of Earth Remote Sensing // *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2020, 24(2): 90-107 (In Russ.). <https://doi.org/10.21869/2223-1560-2020-24-2-90-107>.

Received 30.10.2019

Accepted 06.02.2020

Published 20.04.2020

## Введение

Сегментация относится к стадии предварительной обработки изображений. Она заключается в разбиении изображения на непересекающиеся области на основе однородности характеристик (яркости или цвета пикселей). Сегментация применима во многих практических областях, включая дистанционное зондирование Земли. Один из распространенных подходов к сегментации спутниковых изображений основан на использовании алгоритмов кластеризации данных.

Среди классических методов кластеризации данных особо выделяются методы Уорда [1], Оцу [2], К-средних [3] и модель сегментации Мамфорда-Шаха [4, 5]. Эти методы хорошо известны. Существует множество модификаций. Например, в работе [6] представлен новый метод генерации центра кластера путем уменьшения среднеквадратичной ошибки конечного кластера без значительного увеличения времени выполнения метода К-средних. В работах [7, 8] совершенствуется механизм нахождения начальных центроидов, обеспечивающий эффективное назначение точек подходящим кластерам. В работе [9] совмещается кластеризация методом К-средних с методом нечеткой логики С-средних. В работе [10] совмещаются методы нечеткой логики с методами пороговой обработки. В ней также представлена классифика-

ция пороговых методов сегментации изображений. В работе [11] преодолевается сложность модели Мамфорда-Шаха за счет замены кусочно-гладкой функции кусочно-постоянной функцией.

В работе [12], посвященной выбору характеристик гиперспектральных изображений для пространственной и спектральной кластеризации методом нечеткой логики С-средних, метод Уорда используется в качестве агломеративного алгоритма построения иерархии, в которой каждая спектральная полоса рассматривается как кластер. Итеративный процесс объединения повторяется до тех пор, пока не будет достигнуто желаемое количество кластеров. В работе [13] применяются методы кластеризации для выделения однородных областей водоразделов в задачах дистанционного зондирования. Метод Уорда, продемонстрировавший превосходные по качеству результаты, был применен для формирования двумерной карты объектов. В работе [14] предлагается алгоритм распознавания областей лунных морей на основе метода Уорда.

Несмотря на то, что метод Уорда возвращает результаты приемлемого качества по суммарной квадратичной ошибке, он используется в обработке изображений ограничено из-за высокой вычислительной сложности.

В работе [15] приведены особенности кластеризации спутниковых изображений, среди которых выделяют:

– большой объем данных;

- отсутствие априорной информации о количестве и вероятностных характеристиках классов;

- наличие «шума» и выбросов в данных.

К «хорошим» алгоритмам выдвигают требования:

- низкая вычислительная сложность;

- выделение кластеров любой структуры;

- выделение заранее неизвестного числа кластеров;

- обработки данных в присутствии «шума»;

- простота настройки параметров.

В настоящей работе исследуется применение классических методов кластерного анализа [16, 17] для предварительной обработки цифрового изображения на стадии *сегментации*, которая заключается в разбиении исходного изображения на вложенные изображения «объектов» с целью дальнейшего анализа признаков и распознавания. Заполнение каждого вложенного изображения одинаковыми пикселями с усредненным значением яркости преобразует исходное изображение в свое *приближение*. Качество разбиения и соответствующего приближения изображения из  $N$  пикселей оценивается по величине среднеквадратичного отклонения  $\sigma$  пикселей приближения от пикселей изображения или суммарной квадратичной ошибки  $E=3N\sigma^2$ , где коэффициент 3 учитывает число цветовых компонент в изображении. При *сегментации* пиксели каждого

вложенного изображения составляют единственный связный сегмент. При *кластеризации* пикселей допускается, что вложенное изображение может состоять из нескольких или многих несмежных сегментов исходного изображения. Разбиение и приближение при данном числе кластеров пикселей, в частности сегментов изображения, считается *оптимальным*, если отвечает минимально возможному значению суммарной квадратичной ошибки  $E$  или среднеквадратичного отклонения  $\sigma$ . Тогда *объекты* определяются как кластеры или сегменты оптимального приближения изображения.

В секции 2 излагается модель скоростной кластеризации пикселей. Приводится типовая блок-схема алгоритма и варианты реализации блоков. Описывается программно-алгоритмический инструментарий модели. В секции 3 излагаются экспериментальные результаты обработки стандартных изображений дистанционного зондирования Земли из международной базы данных (USC-SIPI image database). Обсуждаются результаты кластеризации пикселей и сегментации изображений. Сопоставляются временные затраты на обработку изображений в различных режимах. В секции 4 подводятся итоги проделанной работы.

## Материалы и методы

Среди методов кластерного анализа, применимых в обработке изображений, особое место занимает классиче-

ский метод Уорда. Он обрабатывает цветные изображения и возвращает адекватные результаты, но характерная методу высокая вычислительная сложность существенно ограничивает его применение. Приведенная на рис. 1 схема скоростной кластеризации пикселей изображения преодолевает указанный недостаток за счет разделения процесса обработки на три типовых этапа.

Первый этап «а» при помощи операций «merge» (1) и «divide» (3) быстро строит грубую иерархию связных сегментов, генерация которой доступна двумя разными вариантами. Первый вариант – применение модели Мамфорда-Шаха [4, 5], которая заключается в последовательном укрупнении смежных сегментов (на начальных шагах – смежных пикселей). Выбираются такие два смежных сегмента, объединение которых сопровождается минимальным приращением суммарной квадратичной ошибки (3). Второй вариант – разделение изображения на фрагменты регулярной сеткой для их обработки как самостоятельные изображения классическим методом Уорда с последующим объединением иерархий в одну [18].

Второй этап «б» формирует  $g_0$  суперпикселей, фактически, выполняя улучшение качества заданного разбиения при фиксированном числе цветов (кластеров). Для чего разработаны два базовых алгоритма: *SI*-метод (Segmentation Improvement) [19], являющийся сочетанием операций «merge&divide» (6), и *K-meanless* метод (метод *K*-сред-

них-без-средних) [20], реализующий операцию «correct» (5). Множество программных реализаций обусловлено как возможностью комбинированного сочетания пары базовых методов *SI* и *K-meanless* (отдельно, последовательно, циклично), так и версиями самих методов (сегментарная, кластерная).

На третьем этапе «в» выполняется кластеризация суперпикселей методом Уорда [1] (операция «merge» для суперпикселей (1)).

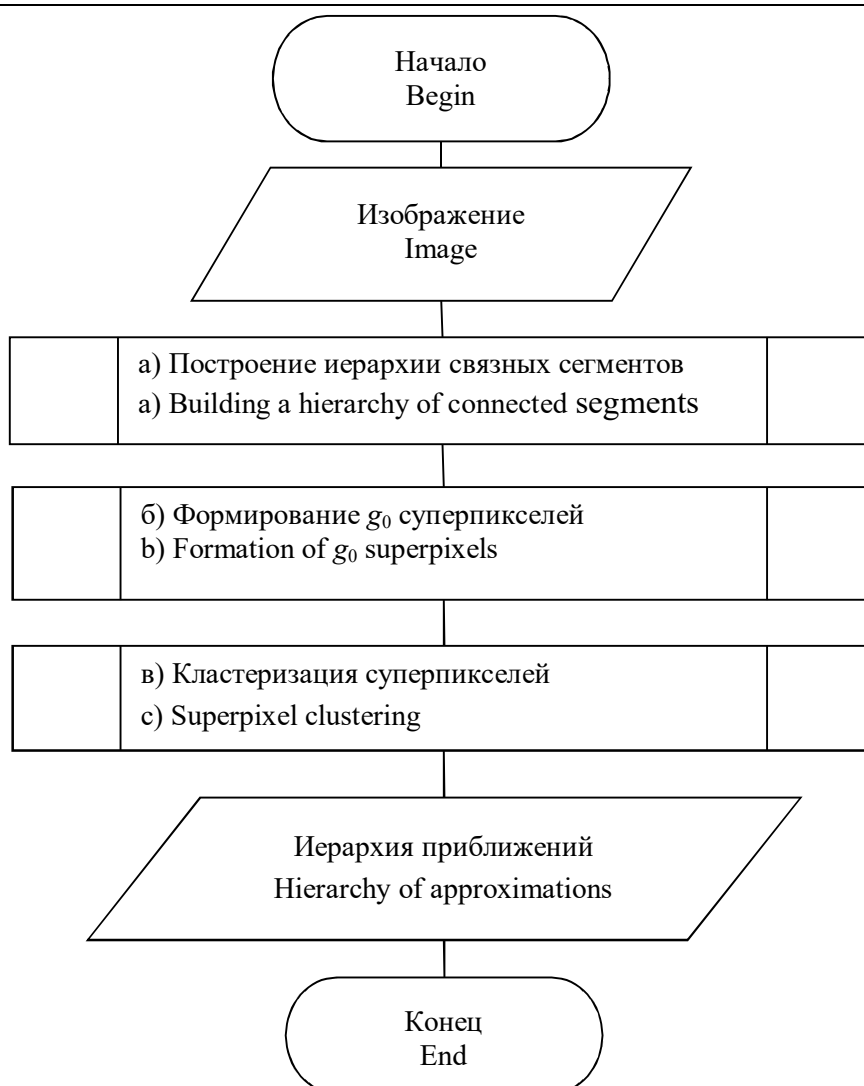
Механизм создания бинарной иерархической последовательности из  $N$  разбиений изображения на кластеры пикселей, кодируемой двумя массивами, состоящих, как и исходное изображение, из  $N$  элементов каждый, где один массив задает дерево, а второй – циклический граф, подробно описан в работах [18, 21].

Основу программно-алгоритмического инструментария схемы скоростной кластеризации пикселей [22] образуют четыре операции с кластерами пикселей, в частности, с сегментами изображения: операция «merge», операция «divide», операция «split», операция «correct».

Все операции минимизируют суммарную квадратичную ошибку  $E$  или среднеквадратичное отклонение  $\sigma$ , связанные равенством:

$$E=3N\sigma^2,$$

где  $N$  – число пикселей в изображении; 3 – коэффициент, указывающий число цветовых составляющих.



**Рис. 1.** Трехэтапная блок-схема скоростной кластеризации пикселей изображения

**Fig. 1.** Three-stage flowchart of the high-speed clustering of the image pixels

Первые две операции («merge» и «divide») используются при построении бинарной иерархии. Пара остальных операций («split» и «correct») используется при ее преобразованиях.

Операция «merge» объединяет кластеры 1 и 2 с числом пикселей  $n_1$  и  $n_2$  соответственно по формуле:

$$\Delta E_{merge} = \frac{n_1 n_2}{n_1 + n_2} \|I_1 - I_2\|^2, \quad (1)$$

где  $I_1$  и  $I_2$  – трехкомпонентные средние значения яркостей пикселей кластеров 1 и 2,  $\| \|^2$  – квадрат Евклидовой разницы.

Критерием выбора пары кластеров (в частности, сегментов) 1 и 2 из доступного множества пар для последующего объединения служит сопутствующий минимум приращения суммарной квадратичной ошибки:

$$(1, 2) = \arg \min \{ \Delta E_{merge}(1, 2) \}. \quad (2)$$

Операция «divide» разделяет кластер 1 на образующую его пару кластеров 1' и 1'':

$$\Delta E_{divide}(1) \equiv -\Delta E_{merge}(1', 1''). \quad (3)$$

Операция «split» выделяет из  $n_1$  пикселей кластера 1 в отдельный кластер любое подмножество из  $k < n_1$  пикселей:

$$\Delta E_{split} = -\frac{kn_1}{n_1 - k} \|I - I_1\|^2, \Delta E_{split} \leq 0, (4)$$

где  $I_1$  и  $I$  – трехкомпонентные средние яркости обсуждаемых  $n_1$  и  $k$  пикселей. Выделение в отдельный кластер пикселей сопровождается отрицательным приращением суммарной квадратичной ошибки, то есть уменьшением суммарной квадратичной ошибки всего разбиения.

Операция «correct» является комбинацией операций «split» и «merge». Она реклассифицирует пиксели посредством их исключения из кластера 1 и отнесения к кластеру 2:

$$\Delta E_{correct} = \frac{kn_2}{n_2 + k} \|I - I_2\|^2 - \frac{kn_1}{n_1 - k} \|I - I_1\|^2, (5)$$

где  $I$  – среднее значение реклассифицируемых  $k$  пикселей, а  $I_1$ ,  $I_2$  – средние значения пикселей кластеров 1 и 2 с числом пикселей  $n_1$  и  $n_2$  соответственно.

Поскольку объединение множеств пикселей  $k$  и  $n_2$  сопровождается приращением суммарной квадратичной ошибки (первое слагаемое формулы (5)), а извлечение множества  $k < n_1$  пикселей из множества пикселей  $n_1$  сопровождается уменьшением ее значения (второе слагаемое формулы (5)), то пара кластеров 1, 2 и множество  $k < n_1$  пикселей выбирается из условия максимального падения значения суммарной квадратичной ошибки:

$$(1, 2, k) = \arg \min \Delta E_{correct} (1, 2, k), \Delta E_{correct} \leq 0.$$

Сочетание операций «merge&divide» обеспечивает улучшение качества приближения изображения в методе сегментации «SI» (segmentation improvement) за счет разделения надвое одного из сегментов (под номером 1) и слияния несовпадающих с ним двух других (с номерами 2 и 3), которое выполняется итеративно по критерию [19]:

$$\begin{aligned} \Delta E(1, 2, 3) &= \Delta E_{divide}(1) + \Delta E_{merge}(2, 3); \\ (1, 2, 3) &= \arg \min (\Delta E(1, 2, 3)); \\ \Delta E(1, 2, 3) &< 0. \end{aligned} (6)$$

На каждой итерации выбирается тройка сегментов, обеспечивающих максимальное падение суммарной квадратичной ошибки, и процесс комбинированного слияния/разделения смежных сегментов продолжается, пока обнаруживаются тройки сегментов, удовлетворяющие условию. В противном случае, обработка завершается. Для приложений SI-метода важно, что число сегментов в результирующем приближении совпадает с числом сегментов исходного приближения.

Посредством перечисленных операций и их комбинаций [22] строится бинарная иерархия кластеров или сегментов и формируется иерархическая последовательность квазиоптимальных разбиений изображения на последовательное число кластеров от 1 до  $N$ . При этом иерархия кластеров (сегментов) считается заданной, если для каждого кластера не менее, чем из одного пикселя, устанавливается пара кластеров, на которые разделяется данный кластер.

## Результаты и их обсуждение

Применение схемы скоростной кластеризации пикселей демонстрируется обработкой снимков дистанционного зондирования Земли, взятых из базы данных Института обработки сигналов и изображений Южно-Калифорнийского университета (Signal and Image Processing Institute, University of Southern California: <http://sipi.usc.edu/database/>). На рис. 2 приведено исходное изображение планеты Земля.

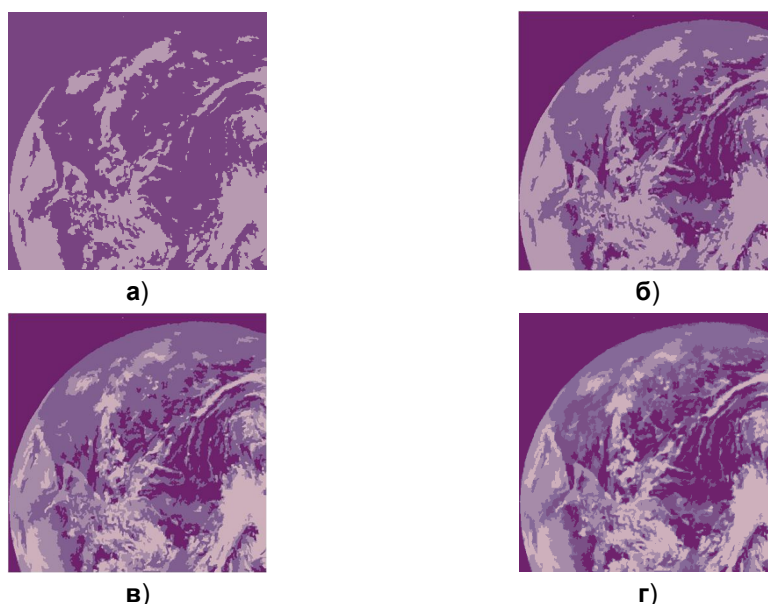


**Рис. 2.** Исходное изображение 2.1.11 «Earth from space» размером 512x512 пикселей

**Fig. 2.** The original image 2.1.11 "Earth from space" size of 512x512 pixels

На сериях рис. 3 и рис. 4 иллюстрируются пикселей и сегментации изображения. Под каждым рисунком отмечено число кластеров/сегментов, на которое разбивается исходное изображение, а также значение суммарной квадратичной ошибки, характеризующей качества данного разбиения. Чем меньше ее значение, тем качество разбиения лучше. Заметим, что кластеризация пикселей дает существенно большее падение значения ошибки аппроксимации, чем процедура сегментации. Это видно, сопоставляя каждое очередное разбиение изображения.


На рис. 5 изображен исходный снимок аэропорта в Сан-Диего. На серии рис. 6 и рис. 7 приведены результаты кластеризации пикселей и сегментации изображений.



**Рис. 3.** Кластеризация пикселей,  $N_{sp}=1000$ : **а** –  $N_{кл}=2$ ,  $\sigma=24,14763$ ; **б** –  $N_{кл}=3$ ,  $\sigma=17,15115$ ; **в** –  $N_{кл}=4$ ,  $\sigma=14,42725$ ; **г** –  $N_{кл}=5$ ,  $\sigma=13,13059$

**Fig. 3.** Pixel clustering,  $N_{sp}=1000$ ): **а** –  $N_{кл}=2$ ,  $\sigma=24,14763$ ; **б** –  $N_{кл}=3$ ,  $\sigma=17,15115$ ; **в** –  $N_{кл}=4$ ,  $\sigma=14,42725$ ; **г** –  $N_{кл}=5$ ,  $\sigma=13,13059$






**Рис. 4.** Сегментация изображений,  $N_{сп}=1$ : **а** –  $N_{сг}=2$ ,  $\sigma=32,58404$ ; **б** –  $N_{сг}=3$ ,  $\sigma=29,19237$ ; **в** –  $N_{сг}=4$ ,  $\sigma=28,17634$ ; **г** –  $N_{сг}=5$ ,  $\sigma=27,40356$

**Fig. 4.** Image segmentation,  $N_{sp}=1$ : **a** –  $N_{cg}=2$ ,  $\sigma=32,58404$ ; **б** –  $N_{cg}=3$ ,  $\sigma=29,19237$ ; **в** –  $N_{cg}=4$ ,  $\sigma=28,17634$ ; **г** –  $N_{cg}=5$ ,  $\sigma=27,40356$




**Рис. 5.** Исходное изображение 2.1.05 «San Diego (North Island NAS)» размером 512x512 пикселей

**Fig. 5.** Original image 2.1.05 "San Diego (North Island NAS)" size of 512x512 pixels



**Рис. 6.** Кластеризация пикселей,  $N_{сп}=1000$ : **а** –  $N_{кл}=2$ ,  $\sigma=28,64477$ ; **б** –  $N_{кл}=3$ ,  $\sigma=20,93470$ ; **в** –  $N_{кл}=4$ ,  $\sigma=18,86713$ ; **г** –  $N_{кл}=5$ ,  $\sigma=17,67230$

**Fig. 6.** Кластеризация пикселей,  $N_{sp}=1000$ : **a** –  $N_{cl}=2$ ,  $\sigma=28,64477$ ; **б** –  $N_{cl}=3$ ,  $\sigma=20,93470$ ; **в** –  $N_{cl}=4$ ,  $\sigma=18,86713$ ; **г** –  $N_{cl}=5$ ,  $\sigma=17,67230$



**Рис. 7.** Сегментация изображений,  $N_{sp}=1$ : **а** –  $N_{cr}=2$ ,  $\sigma=44,86318$ ; **б** –  $N_{cr}=3$ ,  $\sigma=39,58331$ ;  
**в** –  $N_{cr}=4$ ,  $\sigma=38,16740$ ; **г** –  $N_{cr}=5$ ,  $\sigma=37,62308$

**Fig. 7.** Image segmentation,  $N_{sp}=1$ : **а** –  $N_{cr}=2$ ,  $\sigma=44,86318$ ; **б** –  $N_{cr}=3$ ,  $\sigma=39,58331$ ;  
**в** –  $N_{cr}=4$ ,  $\sigma=38,16740$ ; **г** –  $N_{cr}=5$ ,  $\sigma=37,62308$

На рис. 8 приведен аэрокосмический снимок Пентагона в оттенках серого. На серии рис. 9 с каждым очередным разбиением детали здания проявляются более отчетливо, чем на аналогичной серии сегментаций рис. 10.

На рис. 11 изображен Вашингтон в инфракрасном спектре. На серии рис. 12 и 13 приведены результаты кластеризации пикселей и сегментации изображения. Уже на втором кластеризованном разбиении (рис. 11а) просматриваются детали подстилающей поверхности и очертания реки.

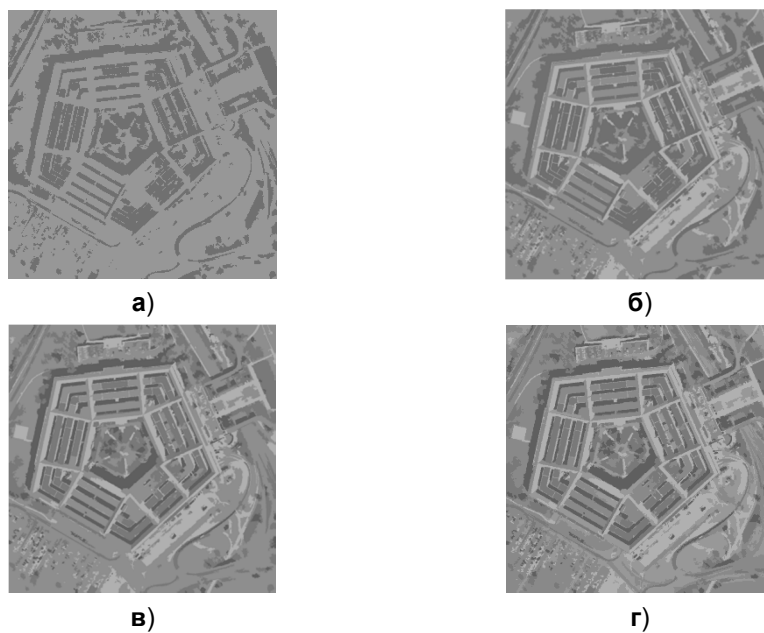
В табл. приводятся значения временных затрат на обработку представленных в работе изображений в различных режимах: кластеризации пикселей и сегментации изображений. В первом столбце указано наименование стан-

дартного тестового изображения из открытой базы данных SIPI. Во втором столбце указан размер стороны изображения в пикселях. Все изображения квадратные. В третьем столбце задается  $N_{sp}$  число суперпикселей – параметр детализации, который принимает значения в диапазоне от 1 до  $N$  числа пикселей в изображении всего.



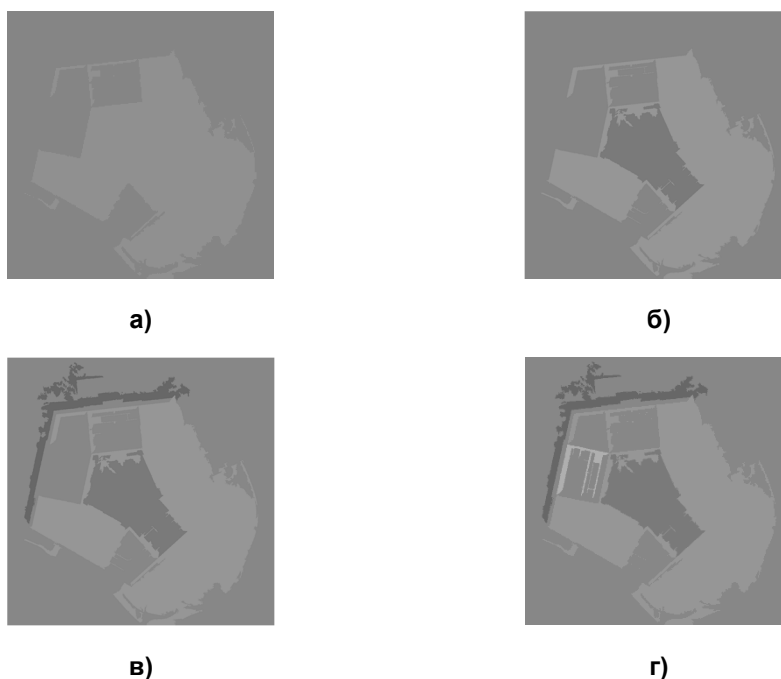
**Рис. 8.** Исходное изображение 3.2.25 «Pentagon», размером 1024x1024 пикселей

**Fig. 8.** Original image 3.2.25 "Pentagon", 1024x1024 pixels in size




**Рис. 9.** Кластеризация пикселей,  $N_{sp}=1000$ : **а** –  $N_{кл}=2$ ,  $\sigma=0,94362$ ; **б** –  $N_{кл}=3$ ,  $\sigma=17,12895$ ;  
**в** –  $N_{кл}=4$ ,  $\sigma=15,50541$ ; **г** –  $N_{кл}=5$ ,  $\sigma=14,59845$

**Fig. 9.** Pixel clustering,  $N_{sp}=1000$ : **а** –  $N_{кл}=2$ ,  $\sigma=0,94362$ ; **б** –  $N_{кл}=3$ ,  $\sigma=17,12895$ ;  
**в** –  $N_{кл}=4$ ,  $\sigma=15,50541$ ; **г** –  $N_{кл}=5$ ,  $\sigma=14,59845$




**Рис. 10.** Сегментация изображений,  $N_{sp}=1$ : **а** –  $N_{сп}=1$ :  $N_{сг}=2$ ,  $\sigma=27,29347$ ; **б** –  $N_{сг}=3$ ,  
 $\sigma=26,43707$ ; **в** –  $N_{сг}=4$ ,  $\sigma=25,71989$ ; **г** –  $N_{сг}=5$ ,  $\sigma=25,47795$

**Fig. 10.** Image segmentation,  $N_{sp}=1$ : **а** –  $N_{сп}=1$ :  $N_{сг}=2$ ,  $\sigma=27,29347$ ; **б** –  $N_{сг}=3$ ,  $\sigma=26,43707$ ;  
**в** –  $N_{сг}=4$ ,  $\sigma=25,71989$ ; **г** –  $N_{сг}=5$ ,  $\sigma=25,47795$




**Рис.11.** Исходное изображение wash-ir «Washington D.C. (infra-red)» размером 2250x2250 пикселей

**Fig. 11.** Original Image wash-ir "Washington D.C. (infra-red)" size of 2250x2250 pixels



**Рис. 12.** Кластеризация пикселей,  $N_{sp}=1000$ : **а** –  $N_{кл}=2$ ,  $\sigma=36,29479$ ; **б** –  $N_{кл}=3$ ,  $\sigma=32,73039$ ; **в** –  $N_{кл}=4$ ,  $\sigma=31,51019$ ; **г** –  $N_{кл}=5$ ,  $\sigma=30,90131$

**Fig.12.** Pixel clustering,  $N_{sp}=1000$ : **а** –  $N_{кл}=2$ ,  $\sigma=36,29479$ ; **б** –  $N_{кл}=3$ ,  $\sigma=32,73039$ ; **в** –  $N_{кл}=4$ ,  $\sigma=31,51019$ ; **г** –  $N_{кл}=5$ ,  $\sigma=30,90131$



**Рис. 13.** Сегментация изображений,  $N_{sp}=1$ : **а** –  $N_{сг}=2$ ,  $\sigma=36,29479$ ; **б** –  $N_{сг}=3$ ,  $\sigma=32,73039$ ; **в** –  $N_{сг}=4$ ,  $\sigma=31,51019$ ; **г** –  $N_{сг}=5$ ,  $\sigma=30,90131$

**Fig. 13.** Image segmentation,  $N_{sp}=1$ : **а** –  $N_{сг}=2$ ,  $\sigma=36,29479$ ; **б** –  $N_{сг}=3$ ,  $\sigma=32,73039$ ; **в** –  $N_{сг}=4$ ,  $\sigma=31,51019$ ; **г** –  $N_{сг}=5$ ,  $\sigma=30,90131$

При значении  $N_{сп}=1$  программа работает в режиме чистой сегментации, рассматривая только пары смежных пикселей как в модифицированной модели Мамфорда-Шаха [4, 5, 22]. Аналогично, при  $N_{сп}=N$  программа работает в режиме чистой кластеризации с квадратичной вычислительной сложностью как в классическом методе Уорда [1]. Практика показывает, что компромисс-

ного значения  $N_{сп}=1000$  достаточно для выделения деталей объекта без потери времени на обработку изображения. В четвертом, пятом, шестом столбцах приводятся временные затраты и скорости обработки изображения на каждом этапе алгоритма. В крайне правом седьмом столбце приводится общее время работы алгоритма для обработки изображения в заданном режиме.

**Таблица.** Сопоставление временных затрат в режимах кластеризации пикселей и сегментации изображений

**Table.** Comparison of time costs in pixel clustering and image segmentation modes

Изображение	Размер стороны	$N_{сп}$	Этап «а»	Этап «б»	Этап «в»	$T, c$
			$t, c$	$t, c$	$t, c$	
			$v, \text{пикс./с}$	$v, \text{пикс./с}$	$v, \text{пикс./с} / v, \text{pix./sec.}$	
2.1.11 «Earth from space»	512	1	8,790			8,7900
			29823			
2.1.11 «Earth from space»	512	1000	9,046	0,023;	1,305	10,374
			28979	11397565	200877	
2.1.05 «San Diego (North Island) NAS»	512	1	13,024			13,024
			20128			
2.1.05 «San Diego (North Island) NAS»	512	1000	14,825	0,009	0,523	15,557
			17683	29127111	501231	
3.2.25 Pentagon	1024	1	60,627			60,627
			17296			
3.2.25 Pentagon	1024	1000	59,832	0,041	1,61	61,484
			17525	25575024	650885	
wash-ir Washington D.C. (in-fra-red)	2250	1	202,862			202,862
			24955			
wash-ir Washington D.C. (in-fra-red)	2250	1000	206,872	0,061	0,909	207,842
			24472	82991803	5569307	

## Выводы

В работе приведена модель вычислительного процесса по преодолению вычислительной сложности, характерной классическому методу Уорда. Описываются варианты реализации путей ее преодоления. Особенность предлагаемой модели заключается в обходе вычислительной сложности за счет разделения процесса на три последовательных этапа. Возможности модели ско-

ростной кластеризации пикселей продемонстрированы на примере обработки изображений дистанционного зондирования Земли. В качестве основных результатов приведены обработанные изображения дистанционного зондирования Земли. Кластеризация пикселей по сравнению с сегментацией изображений позволяет более детально определить как контуры объектов интереса, так и их внутреннюю структуру.

## Список литературы

1. Ward J.H., Jr. Hierarchical grouping to optimize an objective function. *J. Am. Stat. Assoc.* 1963. 58(301): 236–244. <http://doi.org/10.1080/01621459.1963.10500845>.
2. Otsu N.A. Threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics.* 1979. 9(1): 62–66. <http://doi.org/10.1109/TSMC.1979.4310076>.
3. Lloyd S.P. Least squares quantization in PCM. *IEEE Transactions on Information Theory.* 1957/1982. 28(2): 129–137. <http://doi.org/10.1109/TIT.1982.1056489>.
4. Mumford D., Shah J. Boundary detection by minimizing functionals. *IEEE Conference on Computer Vision and Pattern Recognition.* 1985. 17: 137–154.
5. Mumford D., Shah J. Optimal approximations by piecewise smooth functions and associated variational problems. *Communications on pure and applied mathematics.* 1989. 42(5): 577–685. <http://doi.org/10.1002/cpa.3160420503>.
6. Purohit P., Joshi R.A. New Efficient Approach towards k-means Clustering Algorithm. *In International Journal of Computer Applications.* 2013. 65(11): 125–129. <https://pdfs.semanticscholar.org/99bb/dc0435b10476f61a778e0ab00301704c647c.pdf>
7. Yedla M., Pathakota S.R., Srinivasa T.M. Enhanced K-means Clustering Algorithm with Improved Initial Center. *In International Journal of Science and Information Technologies.* 2010. 1(2): 121–125. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.421.7070&rep=rep1&type=pdf>
8. Nazeer K.A.A., Sebastian M. P. Improving the Accuracy and Efficiency of the k-means Clustering Algorithm. *In Proceedings of the World Congress on Engineering.* 2009. [https://www.researchgate.net/profile/K\\_A\\_Nazeer/publication/44260003\\_Improving\\_the\\_Accuracy\\_and\\_Efficiency\\_of\\_the\\_k-means\\_Clustering\\_Algorithm/links/0fcfd51356e00827b8000000.pdf](https://www.researchgate.net/profile/K_A_Nazeer/publication/44260003_Improving_the_Accuracy_and_Efficiency_of_the_k-means_Clustering_Algorithm/links/0fcfd51356e00827b8000000.pdf)

9. Jose A, Ravi S, Sambath M. Brain tumor segmentation using k-means clustering and fuzzy c-means algorithms and its area calculation. *International Journal of Innovative Research in Computer and Communication Engineering*. 2014. 2(3): 3496-3501.
10. Das A., Sabut S.K. Kernelized fuzzy C-means clustering with adaptive thresholding for segmenting liver tumors. *Proceedings on Computer Science*. 2016. 92: 389–395. <http://doi.org/10.1016/j.procs.2016.07.395>.
11. Chan T. F., Vese L. A. Active contours without edges. *Image processing, IEEE Transactions on*. 2001. 10(2): 266–277. <http://w3.mi.parisdescartes.fr/~lomn/Cours/CV/SeqVideo/Articles/ChanLevelSet.pdf>
12. Salem M.B., Etabaa K.S., Bouhlel M.S. Hyperspectral image feature selection for the fuzzy c-means spatial and spectral clustering. In *International Image Processing, Applications and Systems (IPAS) IEEE*. 2016: 1–5. <https://doi.org/doi:10.1109/ipas.2016.7880114>
13. Sardooi E.R., Azareh A., Choubin B., Barkhori S., Singh V.P., Shamshirband S. Applying the remotely sensed data to identify homogeneous regions of watersheds using a pixel-based classification approach. *Applied Geography*. 2019. 111: 102071. <https://doi.org/doi:10.1016/j.apgeog.2019.102071>
14. Xie T, Jiang H, Wang J, Tian X., Xu A.A. A new recognition algorithm of the lunar mare area basing on the DEM contrast. In *International Conference on Advanced Materials and Engineering Structural Technology* (2015 Apr 25). [https://www.researchgate.net/profile/Junlin\\_Wang2/publication/295819542\\_A\\_new\\_recognition\\_algorithm\\_of\\_the\\_lunar\\_mare\\_area\\_based\\_on\\_the\\_DEM\\_contrast/links/56cdbc2408ae85c8233e66f1/A-new-recognition-algorithm-of-the-lunar-mare-area-based-on-the-DEM-contrast.pdf](https://www.researchgate.net/profile/Junlin_Wang2/publication/295819542_A_new_recognition_algorithm_of_the_lunar_mare_area_based_on_the_DEM_contrast/links/56cdbc2408ae85c8233e66f1/A-new-recognition-algorithm-of-the-lunar-mare-area-based-on-the-DEM-contrast.pdf)
15. Пестунов И.А., Синявский Ю.Н. Алгоритмы кластеризации в задачах сегментации спутниковых изображений // *Вестник КемГУ*. 2012. 4(52): 110–125. URL: <https://cyberleninka.ru/article/v/algoritmy-klasterizatsii-v-zadachah-segmentatsii-sputnikovyh-izobrazheniy>
16. Айвазян С.А., Бухштабер В.М., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Классификация и снижение размерности. М.: Финансы и статистика, 1989. 607 с.
17. Мандель И.Д. Кластерный анализ. М.: Финансы и статистика, 1988. 176 с.
18. Харинов М.В., Ханыков И.Г. Применение метода Уорда для кластеризации пикселей цифрового изображения // *Вестник БГУ. Математика, информатика*. 2016. 4: 34–42. <http://doi.org/10.18101/2304-5728-2016-4-34-42>.
19. Харинов М.В., Ханыков И.Г. Оптимизация кусочно-постоянного приближения сегментированного изображения // *Труды СПИИРАН*. 2015. 3(40): 183–202. <https://doi.org/10.15622/sp.40.12>.
20. Khanykov I.G., Kharinov M.V., Patel C. Image segmentation improvement by reversible segment merging. 2017 International Conference on Soft Computing and its Engineering Applications (icSoftComp). IEEE, 2017. <http://doi.org/10.1109/ICSOFTCOMP.2017.8280096>

21. Харинов М.В. Кластеризация пикселей иерархически структурированного изображения // *Информационно-измерительные и управляющие системы*. 2019. 17(5): 30–43. <http://doi.org/10.18127/j20700814-201905-05>.

22. Харинов М.В. Обобщение трех подходов к оптимальной сегментации цифрового изображения // *Труды СПИИРАН*. 2013. 2(25): 294–316. <http://www.mathnet.ru/links/d13b2a4e766e53f82eb216ba6367bf29/trspsy552.pdf>

## References

1. Ward J.H., Jr. Hierarchical grouping to optimize an objective function. *J. Am. Stat. Assoc.*, 1963, no. 58(301), pp. 236–244. <http://doi.org/10.1080/01621459.1963.10500845>.

2. Otsu N.A. Threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 1979, no. 9(1), pp. 62–66. <http://doi.org/10.1109/TSMC.1979.4310076>.

3. Lloyd S.P. Least squares quantization in PCM. *IEEE Transactions on Information Theory*. 1957/1982, no. 28(2), pp. 129–137. <http://doi.org/10.1109/TIT.1982.1056489>.

4. Mumford D., Shah J. Boundary detection by minimizing functionals. *IEEE Conference on Computer Vision and Pattern Recognition*, 1985, no. 17, pp. 137–154.

5. Mumford D., Shah J. Optimal approximations by piecewise smooth functions and associated variational problems. *Communications on pure and applied mathematics*, 1989, no. 42(5), pp. 577–685. <http://doi.org/10.1002/cpa.3160420503>.

6. Purohit P., Joshi R.A. New Efficient Approach towards k-means Clustering Algorithm. *In International Journal of Computer Applications*, 2013, no. 65(11), pp. 125–129. <https://pdfs.semanticscholar.org/99bb/dc0435b10476f61a778e0ab00301704c647c.pdf>

7. Yedla M., Pathakota S.R., Srinivasa T.M. Enhanced K-means Clustering Algorithm with Improved Initial Center. *In International Journal of Science and Information Technologies*, 2010, no. 1(2), pp. 121–125. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.421.7070&rep=rep1&type=pdf>

8. Nazeer K.A.A., Sebastian M. P. Improving the Accuracy and Efficiency of the k-means Clustering Algorithm. *In Proceedings of the World Congress on Engineering*. 2009. [https://www.researchgate.net/profile/K\\_A\\_Nazeer/publication/44260003\\_Improving\\_the\\_Accuracy\\_and\\_Efficiency\\_of\\_the\\_k-means\\_Clustering\\_Algorithm/links/0fcfd51356e00827b8000000.pdf](https://www.researchgate.net/profile/K_A_Nazeer/publication/44260003_Improving_the_Accuracy_and_Efficiency_of_the_k-means_Clustering_Algorithm/links/0fcfd51356e00827b8000000.pdf)

9. Jose A, Ravi S, Sambath M. Brain tumor segmentation using k-means clustering and fuzzy c-means algorithms and its area calculation. *International Journal of Innovative Research in Computer and Communication Engineering*, 2014, no. 2(3), pp. 3496-3501.

10. Das A., Sabut S.K. Kernelized fuzzy C-means clustering with adaptive thresholding for segmenting liver tumors. *Proceedings on Computer Science*, 2016, no. 92, pp. 389–395. <http://doi.org/10.1016/j.procs.2016.07.395>.



11. Chan T. F., Vese L. A. Active contours without edges. *Image processing, IEEE Transactions on*. 2001, no. 10(2), pp. 266–277. <http://w3.mi.parisdescartes.fr/~lomn/Cours/CV/SeqVideo/Articles/ChanLevelSet.pdf>
12. Salem M.B., Etabaa K.S., Bouhlel M.S. Hyperspectral image feature selection for the fuzzy c-means spatial and spectral clustering. In *International Image Processing, Applications and Systems (IPAS) IEEE*. 2016: 1–5. <https://doi.org/doi:10.1109/ipas.2016.7880114>
13. Sardooi E.R., Azareh A., Choubin B., Barkhori S., Singh V.P., Shamshirband S. Applying the remotely sensed data to identify homogeneous regions of watersheds using a pixel-based classification approach. *Applied Geography*. 2019. 111: 102071. <https://doi.org/doi:10.1016/j.apgeog.2019.102071>
14. Xie T, Jiang H, Wang J, Tian X., Xu A.A. A new recognition algorithm of the lunar mare area basing on the DEM contrast. In *International Conference on Advanced Materials and Engineering Structural Technology* (2015 Apr 25). [https://www.researchgate.net/profile/Junlin\\_Wang2/publication/295819542\\_A\\_new\\_recognition\\_algorithm\\_of\\_the\\_lunar\\_mare\\_area\\_based\\_on\\_the\\_DEM\\_contrast/links/56cdbc2408ae85c8233e66f1/A-new-recognition-algorithm-of-the-lunar-mare-area-based-on-the-DEM-contrast.pdf](https://www.researchgate.net/profile/Junlin_Wang2/publication/295819542_A_new_recognition_algorithm_of_the_lunar_mare_area_based_on_the_DEM_contrast/links/56cdbc2408ae85c8233e66f1/A-new-recognition-algorithm-of-the-lunar-mare-area-based-on-the-DEM-contrast.pdf)
15. Pestunov I.A., Sinyavskiy Yu.N. Algoritmy klasterizatsii v zadachakh segmentatsii sputnikovykh izobrazhenii [Clustering Algorithms in Satellite Images Segmentation Tasks]. *Vestnik KemGU = Bulletin of Kemerovo State University*, 2012, no. 4(52), pp. 110–125 (in Russ.). Available at: <https://cyberleninka.ru/article/v/algoritmy-klasterizatsii-v-zadachah-segmentatsii-sputnikovykh-izobrazheniy>.
16. Aivazyan S.A., Bukhshtaber V.M., Enyukov I.S., Meshalkin L.D. *Prikladnaya statistika: Klassifikatsiya i snizhenie razmernosti* [Applied statistics: Classification and reduction of dimension]. Moscow, Finansy i statistika Publ., 1989, 607 p. (In Russ.).
17. Mandel' I.D. *Klasternyi analiz* [Cluster Analysis]. Moscow, Finansy i statistika Publ., 1988, 176 p. (in Russ.)
18. Kharinov M.V., Khanykov I.G. Primenenie metoda Uorda dlya klasterizatsii pikselei tsifrovogo izobrazheniya [Utilization of Ward's Method for Clustering of Pixels of Color Image]. *Vestnik BGU. Matematika, informatika = BSU Bulletin. Mathematics, Informatics*, 2016, no. 4, pp. 34–42 (In Russ.) <http://doi.org/10.18101/2304-5728-2016-4-34-42>.
19. Kharinov M.V., Khanykov I.G. Optimizatsiya kusochno-postoyannogo priblizheniya segmentirovannogo izobrazheniya [Optimization of Piecewise Constant Approximation for Segmented Image]. *Trudy SPIIRAN = SPIIRAS Proceedings*, 2015, no. 3(40), pp. 183-202 (In Russ.) <https://doi.org/10.15622/sp.40.12>.
20. Khanykov I.G., Kharinov M.V., Patel C. Image segmentation improvement by re-versible segment merging . *2017 International Conference on Soft Computing and its Engineering Applications (icSoftComp)*. IEEE, 2017, <http://doi.org/10.1109/ICSOFTCOMP.2017.8280096>.

21. Kharinov M.V. Klasterizatsiya pikselei ierarkhicheski strukturirovannogo izobrazheniya. Informatsionno-izmeritel'nye i upravlyayushchie sistemy [Clustering of pixels for a hierarchically structured image]. *Informatsionno-izmeritel'nye i upravlyayshchie sistemy = Information-measuring and Control Systems*, 2019, no. 17(5), pp. 30–43 (In Russ.). <http://doi.org/10.18127/j20700814-201905-05>.

22. Kharinov M.V. Obobshchenie trekh podkhodov k optimal'noi segmentatsii tsifrovogo izobrazheniya [A generalization of three approaches to an optimal segmentation of digital image]. *Trudy SPIIRAN = Tr. SPIIRAN*, 2013, no. 25, pp. 294–316. (In Russ.). Available at: <http://www.mathnet.ru/links/d13b2a4e766e53f82eb216ba6367bf29/trspy552.pdf>

---

### Информация об авторе / Information about the Author

**Ханыков Игорь Георгиевич**, магистр техники и технологии, младший научный сотрудник, Санкт-Петербургский Институт информатики и автоматизации Российской академии наук (СПИИРАН), г. Санкт-Петербург, Российская Федерация, e-mail: [igk@iias.spb.su](mailto:igk@iias.spb.su), ORCID 0000-0001-6284-0839, Researcher ID K-9875-2018,

**Igor G. Khanykov**, Master of Computer Sciences, Junior Research Officer, St.Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences (SPIIRAS), St. Petersburg, Russian Federation, e-mail: [igk@iias.spb.su](mailto:igk@iias.spb.su), ORCID 0000-0001-6284-0839, Researcher ID K-9875-2018,