

# Подход к построению ансамбля непараметрических алгоритмов кластеризации для сегментации спутниковых изображений

И.А. Пестунов<sup>а</sup>, С.А. Рылов<sup>а</sup>, Ю.Н. Синявский<sup>а</sup>, В.Б. Бериков<sup>б</sup>

<sup>а</sup>Институт вычислительных технологий СО РАН, 630090, пр. академика Лаврентьева, 6, Новосибирск, Россия

<sup>б</sup>Институт математики им. С.Л. Соболева СО РАН, 630090, пр. академика Коптюга, 4, Новосибирск, Россия

---

## Аннотация

Статья посвящена применению ансамблевого подхода в задачах сегментации мультиспектральных спутниковых изображений с использованием непараметрических алгоритмов кластеризации данных. Подход основан на формировании согласованной матрицы различий для нескольких вариантов разбиения данных на кластеры. Вычислительная эффективность достигается благодаря предварительной группировке данных и переходу к обработке представителей групп. Приведено два способа выбора представителей. На примере плотностного и сеточного алгоритмов показано, что формирование ансамбля позволяет повысить устойчивость и качество результатов сегментации.

*Ключевые слова:* ансамблевый подход; согласованная матрица различий; непараметрические алгоритмы кластеризации; сегментация мультиспектральных изображений

---

## 1. Введение

Сегментация является одним из важнейших этапов анализа цифровых изображений [1]. Она заключается в разбиении изображения на непересекающиеся области на основе схожести их спектральных или пространственных характеристик (текстура, размер, форма и т.п.). Методы сегментации нашли широкое применение во многих прикладных областях, в том числе в дистанционном зондировании Земли [2], интерес к которому в последние годы непрерывно возрастает.

Наиболее распространенный подход к сегментации спутниковых изображений основан на использовании алгоритмов кластеризации данных [3]. В этом случае задачу кластеризации, как правило, приходится решать при отсутствии каких-либо априорных сведений о числе кластеров и их вероятностных характеристиках. В этих условиях наиболее подходящими являются непараметрические плотностные алгоритмы, которые не требуют жестких предположений о виде функции плотности распределения и позволяют выделять кластеры сложной формы [4]. Кластеры определяются как области в пространстве признаков с высокой плотностью распределения данных, разделенные областями с низкой плотностью. Для непараметрического оценивания плотности часто используются гистограммная оценка и оценка Розенблатта–Парзена. Их существенным недостатком является высокая чувствительность к так называемому параметру сглаживания. Неустойчивость получаемых результатов затрудняет процесс настройки параметров при решении практических задач. Кроме того, недостатком непараметрических алгоритмов является высокая вычислительная трудоемкость, которая ограничивает возможность их применения для обработки больших массивов данных (спутниковых изображений, генетических данных, интернет-данных и т.п.) [5,6].

Известно [6-15], что устойчивость решений в задачах кластеризации может быть повышена благодаря использованию ансамблевого подхода, который является одним из наиболее перспективных направлений в кластерном анализе. Ансамблевый подход заключается в формировании согласованного результата кластеризации основе нескольких вариантов разбиения данных. Было показано [6,7,10], что комбинирование различных кластерных решений позволяет повысить качество результатов и их устойчивость к изменению параметров. При построении ансамблевого алгоритма кластеризации требуется решить два ключевых вопроса – как получить разнообразные разбиения и каким образом их согласовать. Существует четыре основных способа получения начальных разбиений [7]: использование различных алгоритмов кластеризации [9]; использование некоторого алгоритма кластеризации с разными параметрами [8]; выбор различных подмножеств признаков [13] и использование различных подмножеств данных [10]. При сочетании различных результатов кластеризации также возникает проблема установления соответствия меток кластеров [7].

Оптимальный комбинированный результат может быть получен путем нахождения «среднего разбиения» (median partition), то есть разбиения, минимизирующего сумму расстояний (различий) до всех разбиений кластерного ансамбля. Доказано, что эта задача является NP-трудной [14]. Поэтому на практике используются другие методы, такие как разделение гиперграфа, голосование, максимизация взаимной информации и т.п. Однако эти методы также являются вычислительно трудоемкими [9,10], поэтому в настоящее время активно ведутся исследования с целью повышения их быстродействия [8].

Одним из наиболее эффективных методов построения ансамблевого решения является использование согласованной матрицы попарного сходства/различия (co-association matrix) [16]. Элементы этой матрицы характеризуют попарную схожесть объектов как количество разбиений, в которых эти объекты относятся к одному кластеру. Для получения итогового решения матрица различий используется как матрица расстояний между объектами. К ней применяется один из стандартных иерархических алгоритмов кластеризации. Данный метод не требует совпадения количества кластеров

во всех разбиениях. Это условие необходимо для непараметрической кластеризации, когда число получаемых кластеров заранее не определено.

В настоящей работе предлагается подход к построению ансамбля непараметрических алгоритмов кластеризации на основе согласованной матрицы различий с использованием представителей данных. Он позволяет разрабатывать вычислительно эффективные алгоритмы сегментации для обработки мультиспектральных спутниковых изображений.

## 2. Описание и теоретическое обоснование предлагаемого подхода

В данной работе ансамбль предлагается формировать из  $L$  частных решений, полученных в результате выполнения непараметрического алгоритма кластеризации с различными значениями параметра сглаживания. Метод построения коллективного решения может быть описан следующим образом.

Пусть с помощью некоторого алгоритма кластеризации  $\mu = \mu(\theta)$ , зависящего от случайного вектора параметров  $\Theta \in \Theta$  (где  $\Theta$  – некоторое допустимое множество параметров), получен набор частных решений  $G = \{G^{(1)}, \dots, G^{(l)}, \dots, G^{(L)}\}$ , где  $G^{(l)}$  –  $l$ -й вариант кластеризации, содержащий  $M^{(l)}$  кластеров.

Обозначим через  $H(\theta_l)$  бинарную матрицу  $H(\theta_l) = \{H_{i,j}(\theta_l)\}$  размерности  $N \times N$ , которая вводится для  $l$ -й группировки, следующим образом:

$$H_{i,j}(\theta_l) = \begin{cases} 0, & \text{если объекты отнесены в один кластер,} \\ 1, & \text{иначе,} \end{cases}$$

где  $i, j = 1, \dots, N, i \neq j$ .

После построения  $L$  частных решений можно сформировать согласованную матрицу различий

$$\mathbf{H} = \{\mathbf{H}_{i,j}\}, \quad \mathbf{H}_{i,j} = \frac{1}{L} \sum_{l=1}^L H_{i,j}(\theta_l),$$

где  $i, j = 1, \dots, N$ . Величина  $\mathbf{H}_{i,j}$  равна частоте классификации  $x_i$  и  $x_j$  в разные группы в наборе группировок  $G$ . Близкое к нулю значение величины означает, что данные объекты имеют большой шанс попадания в одну и ту же группу. Близкое к единице значение этой величины говорит о том, что шанс оказаться в одной группе у объектов незначителен.

После вычисления согласованной матрицы различий, для нахождения коллективного решения будем применять стандартный агломеративный метод построения дендрограммы, который в качестве входной информации использует попарные расстояния между объектами. При этом расстояния между группами будем определять по принципу «средней связи», т.е. как среднее арифметическое попарных расстояний между объектами, входящими в группы. Процесс объединения продолжается до тех пор, пока расстояние между ближайшими группами не превысит заданное пороговое значение. Этот метод обладает тем достоинством, что он позволяет выделять иерархическую структуру кластеров, которая упрощает процесс интерпретации результатов.

Для исследования свойств предложенного метода формирования коллективного решения рассмотрим его вероятностную модель.

Предположим, что имеется некоторая скрытая (непосредственно ненаблюдаемая) переменная  $U$ , которая задает принадлежность каждого объекта к некоторому из  $M \geq 2$  классов. Каждый класс характеризуется определенным законом условного распределения  $p(x|U=r) = f_r(x)$ ,  $r = 1, \dots, M$ . Рассмотрим следующую вероятностную модель генерации данных. Пусть для каждого объекта определяется класс, к которому он относится, в соответствии с априорными вероятностями  $P_r = P(U=r)$ ,  $r = 1, \dots, M$ , где  $\sum_{r=1}^M P_r = 1$ . Затем в соответствии с распределением  $f_r(x)$  определяется значение  $x$ . Указанная процедура проводится независимо для каждого объекта.

Пусть с помощью некоторого алгоритма кластерного анализа  $\mu$  строится разбиение множества объектов  $X$  на  $M$  подмножеств. Поскольку нумерация кластеров не играет роли, удобнее рассматривать отношение эквивалентности, т.е. указывать, относит ли алгоритм  $\mu$  каждую пару объектов в один и тот же класс, либо в разные классы. Определим для каждой пары объектов  $a$  и  $b$  величину

$$\mathbf{H}_{a,b}(\mu) = \begin{cases} 0, & \text{если объекты отнесены в один кластер,} \\ 1, & \text{иначе,} \end{cases}$$

где  $a, b \in X, a \neq b$ .

Выберем произвольную пару  $a$  и  $b$  различных объектов выборки.

Пусть  $P_U = P(U(a) \neq U(b))$  – вероятность отнесения объектов к различным классам. Например, при  $M = 2$  указанная вероятность равна

$$P_U = 1 - P(U(a) = 1 | a)P(U(b) = 1 | b) - P(U(a) = 2 | a)P(U(b) = 2 | b) = 1 - \sum_{r=1}^2 \frac{f_r(a)f_r(b)P_r^2}{p(a)p(b)},$$

где  $p(\omega) = \sum_{r=1}^2 f_r(\omega)P_r$ ,  $\omega = a, b$ .

Обозначим вероятность ошибки, которую может совершить алгоритм  $\mu$  при классификации  $a$  и  $b$  через  $P_{er}(\mu)$ , где

$$P_{er}(\mu) = \begin{cases} P_U, & \text{если } \mathbf{H}_{a,b}(\mu) = 0, \\ 1 - P_U, & \text{если } \mathbf{H}_{a,b}(\mu) = 1. \end{cases}$$

Легко заметить, что

$$P_{er}(\mu) = (1 - \mathbf{H}_{a,b}(\mu))P_U + \mathbf{H}_{a,b}(\mu)(1 - P_U) = P_U + (1 - 2P_U)\mathbf{H}_{a,b}(\mu).$$

Алгоритм  $\mu$  зависит от случайного вектора параметров  $\Theta \in \Theta: \mu = \mu(\Theta)$ . Чтобы подчеркнуть зависимость результатов работы от параметра  $\Theta$ , в дальнейшем будем обозначать  $\mathbf{H}_{a,b}(\mu(\Theta)) = \mathbf{H}_{a,b}(\Theta)$ ,  $P_{er}(\mu(\Theta)) = P_{er}(\Theta)$ .

Пусть в результате  $L$ -кратного применения алгоритма  $\mu$  со случайно и независимо отобранными параметрами  $\Theta_1, \dots, \Theta_L$  получен набор решений  $H(\theta_1), \dots, H(\theta_L)$ . Для определенности, будем считать, что  $L$  – нечетно. Коллективным (ансамблевым) решением по большинству голосов будем называть функцию

$$\mathbf{H}(H(\theta_1), \dots, H(\theta_L)) = \begin{cases} 0, & \text{если } \frac{1}{L} \sum_{i=1}^L H(\theta_i) < \frac{1}{2}, \\ 1, & \text{иначе.} \end{cases}$$

В рамках описанной модели для предложенного коллективного решения справедливы следующие утверждения [16].

**Утверждение 1.** Математическое ожидание и дисперсия величины вероятности ошибки для алгоритма  $\mu(\Theta)$  равны соответственно:

$$\begin{aligned} E_{\Theta} P_{er}(\Theta) &= P_U + (1 - 2P_U)P_H, \\ \text{Var}_{\Theta} P_{er}(\Theta) &= (1 - 2P_U)^2 P_H(1 - P_H), \end{aligned}$$

где  $P_H = P(H(\Theta) = 1)$ .

Обозначим через  $P_{er}(\Theta_1, \dots, \Theta_L)$  случайную функцию, принимающей при фиксированных аргументах значение, равное вероятности ошибки, которую может совершить ансамблевый алгоритм при классификации  $a$  и  $b$ . Здесь через  $\Theta_1, \dots, \Theta_L$  обозначены статистические копии случайного вектора  $\Theta$ . Рассмотрим поведение вероятности ошибки для коллективного решения.

**Утверждение 2.** Математическое ожидание и дисперсия величины вероятности ошибки для коллективного решения равны соответственно:

$$\begin{aligned} E_{\Theta_1, \dots, \Theta_L} P_{er}(\Theta_1, \dots, \Theta_L) &= P_U + (1 - 2P_U)P_{H,L}, \\ \text{Var}_{\Theta_1, \dots, \Theta_L} P_{er}(\Theta_1, \dots, \Theta_L) &= (1 - 2P_U)^2 P_{H,L}(1 - P_{H,L}), \end{aligned}$$

где  $P_{H,L} = P\left(\frac{1}{L} \sum_{i=1}^L H(\Theta_i) \geq \frac{1}{2}\right) = \sum_{l=\lfloor L/2 \rfloor + 1}^L C_L^l P_H^l (1 - P_H)^{L-l}$ ,  $[\cdot]$  означает целую часть числа.

Вспользуемся следующей априорной информацией об алгоритме кластерного анализа. Будем считать, что ожидаемая вероятность ошибочной классификации  $E_{\Theta} P_{er}(\Theta) < 1/2$ . То есть ожидается, что алгоритм  $\mu$  проводит классификацию с лучшим качеством, нежели алгоритм случайного равновероятного выбора. Из утверждения 1 следует, что выполняется один из двух вариантов: а)  $P_H > 1/2$  и  $P_U > 1/2$ ; б)  $P_H < 1/2$  и  $P_U < 1/2$ . Рассмотрим, для определенности, первый случай.

**Утверждение 3.** Если  $E_{\Theta} P_{er}(\Theta) < 1/2$ , и при этом  $P_H > 1/2$  и  $P_U > 1/2$ , то при увеличении мощности ансамбля ожидаемая вероятность ошибочной классификации уменьшается, стремясь в пределе к  $1 - P_U$ , а дисперсия величины вероятности ошибки стремится к нулю.

Последнее утверждение позволяет сделать вывод о том, что при выполнении вполне естественных условий использование ансамблевого подхода позволяет улучшить качество кластеризации.

### 3. Снижение вычислительной сложности за счет выбора представителей

Метод построения ансамблевого решения на основе согласованной матрицы различий требует формирования и обработки матрицы размера  $N \times N$  ( $N$  – число пикселей изображения), что существенно затрудняет его применение для сегментации изображений. Выходом из этой ситуации является переход от обработки отдельных элементов данных (пикселей) к обработке групп элементов. Способ формирования этих групп и выбора их представителей может зависеть от особенностей конкретного алгоритма. В данной работе предлагаются два способа формирования групп данных для построения ансамбля.

Первый способ позволяет комбинировать результаты кластеризации, полученные произвольными алгоритмами. Элементы исходных данных объединяются в одну группу, если во всех разбиениях они отнесены в один кластер. Согласованная матрица различий строится на множестве полученных групп. При этом подходе число групп пропорционально числу кластеров в разбиениях и мощности ансамбля.

Второй способ позволяет формировать ансамблевое решение для непараметрических алгоритмов кластеризации, основанных на гистограммной оценке или оценке плотности Розенблатта–Парзена. В этом случае каждый кластер содержит одну или несколько мод (локальных максимумов) плотности, которые определяются в процессе работы алгоритма. Данные разбиваются на группы, каждая из которых соответствует отдельной моде. Эти моды используются в качестве представителей отдельных групп. Согласованная матрица различий формируется на множестве

представителей из базового разбиения. В качестве базового используется разбиение, полученное при наименьшем значении параметра сглаживания (наиболее подробное разбиение из ансамбля). Группы относятся к тем же кластерам, что и их представители. При этом способе размер согласованной матрицы различий пропорционален числу кластеров в базовом разбиении.

Первый способ применялся при разработке алгоритма EMeanSC [17], а второй – при создании алгоритмов ECCA [18] и HECA [19]. В этих алгоритмах в качестве элементов ансамбля используются алгоритмы MeanSC (на основе оценки плотности Розенблатта–Парзена), CCA и HCA (на основе гистограммной оценки плотности) соответственно.

#### 4. Экспериментальные исследования

Многочисленные эксперименты показали, что предложенный ансамблевый подход позволяет упростить процедуру подбора параметров и повысить устойчивость и качество результатов кластеризации.

**Эксперимент 1.** В эксперименте используется двумерная модель данных, состоящая из трех классов по 1000 точек в каждом и равномерно распределенного «шума». На рис. 1 представлены исходные данные и результаты обработки алгоритмами MeanSC (элементы ансамбля) и EMeanSC. Для корректного разделения данных с помощью алгоритма MeanSC требуется тщательная настройка параметров, в то время как ансамблевый алгоритм позволяет выделить три кластера данных и кластер «шум» (обозначенный на рис. 1,б черными точками) даже при использовании неудачных промежуточных результатов.

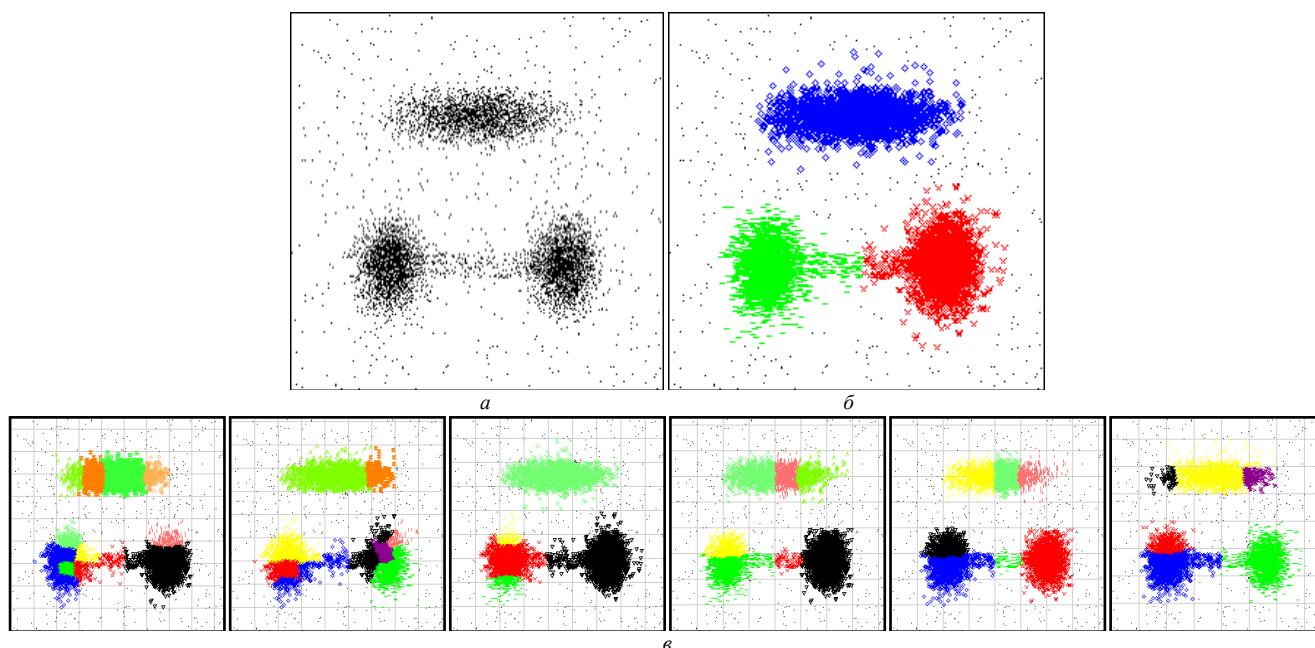


Рис. 1. Исходные данные (а), результаты обработки алгоритмом EMeanSC (б) и алгоритмом MeanSC с разными значениями параметров (в).




Рис. 2. Модель данных «Бананы» (а) и зависимость точности кластеризации от значения параметра сетки для алгоритмов CCA и ECCA (б).

**Эксперимент 2.** Как известно, результаты, получаемые с помощью непараметрических алгоритмов кластеризации, сильно зависят от значений настраиваемых параметров. Особо ярко это проявляется при использовании сеточных алгоритмов кластеризации (рис. 2,б). Тонкая настройка параметров для каждой отдельно взятой задачи возможна, однако это долгий и кропотливый процесс. Использование ансамблевого подхода значительно повышает устойчивость получаемых результатов, что существенно упрощает подбор параметров.

В данном случае имеется эталонное разбиение, поэтому точность кластеризации определяется, как процент правильно расклассифицированных элементов. Для этого каждому классу эталонного разбиения ставится в соответствие кластер (не более одного), в который попало наибольшее число элементов из этого класса.

Для демонстрации повышения устойчивости результатов при использовании ансамблевого подхода рассматривается линейно неразделимая двумерная модель данных «бананы», состоящая из 400 точек, которая построена с помощью инструмента PRTOOLS [20] с параметром  $\sigma=0.7$  (рис. 2а). На рис. 2б представлен график зависимости точности кластеризации этих данных от значения параметра сетки  $m$  для алгоритма  $CCA(m, T)$  и для ансамблевого алгоритма  $ECCA(m, L, T)$ , использующего 5 и 10 элементов ансамбля. Параметр  $T$  во всех случаях принимал фиксированное значение, равное 0.3. Как видно из графика, устойчивость получаемых результатов повышается с ростом мощности ансамбля (числа используемых сеток).

**Эксперимент 3.** На рис. 3б представлен результат кластеризации изображения ансамблевым алгоритмом  $ECCA$  (при восьми элементах ансамбля). Размер изображения составляет  $640 \times 480$  пикселей. Время обработки составило всего 0.04 с. Алгоритм  $ECCA$  позволил выделить два неоднородных по цветам объекта: самолет и фон. Аналогичный результат также получен с помощью алгоритма  $E\text{MeanSC}$  (при трех элементах ансамбля). В то же время алгоритмы  $CCA$  и  $\text{MeanSC}$ , как и наиболее распространенные алгоритмы кластеризации К-средних и  $ISODATA$ , не позволяют выделить эти объекты как единое целое.




Рис. 3. Исходное изображение (а) и результат кластеризации разработанными алгоритмами (б), алгоритмами К-средних (в) и  $ISODATA$  (г).

**Эксперимент 4.** На рис. 4 представлен результат кластеризации мультиспектрального спутникового изображения г. Новосибирска, полученного со спутника Landsat-8 15 июня 2014 года. Обработке подвергался фрагмент снимка размером  $3000 \times 4000$  пикселей. Сегментация выполнялась алгоритмом  $ECCA$  (восемь элементов ансамбля) с использованием 1, 3, 5 и 6-го спектральных каналов. Время обработки составило 1.2 с.




Рис. 4. Фрагмент изображения со спутника Landsat-8 (RGB-композит, каналы 4, 3, 2) (а) и результат его сегментации алгоритмом  $ECCA$  (б).

## 5. Заключение

В статье представлен подход к построению ансамблей непараметрических алгоритмов кластеризации для сегментации изображений. Приведено два способа выбора представителей для снижения вычислительной сложности. Результаты экспериментов на модельных данных и реальных изображениях подтверждают высокое качество получаемых результатов и их устойчивость к изменению настраиваемых параметров.

## Литература

- [1] Гонсалес, Р. Цифровая обработка изображений / Р. Гонсалес, Р. Вудс. – М: Техносфера, 2006. – С. 812.
- [2] Dey, V. A review on image segmentation techniques with remote sensing perspective / V. Dey, Y. Zhang, M. Zhong // ISPRS TC VII Symposium – 100 Years ISPRS. – Vienna, Austria, July 5-7 2010. – Vol. XXXVIII, Part 7A. – P. 31-42.
- [3] Пестунов, И.А. Алгоритмы кластеризации в задачах сегментации спутниковых изображений / И.А. Пестунов, Ю.Н. Синявский // Вестник Кемеровского государственного университета. – 2012. – № 4/2 (52). – С. 110-125.
- [4] Krstinic, D. Fast two-step histogram-based image segmentation / D. Krstinic, A.K. Skelin, I. Slapnicar // Image Processing, IET. – 2011. – Vol. 5, N 1. – P. 63-72.
- [5] Mercer, D.P. Clustering Large Datasets. [Electronic resource]. – 2003. – Access mode: <http://www.stats.ox.ac.uk/~mercer/documents/Transfer.pdf> (06.02.2017).
- [6] Jain, A.K. Data clustering: 50 years beyond K-means / A.K. Jain // Pattern recognition letters. – 2010. – Vol. 31, N 8. – P. 651-666.
- [7] Ghaemi, R. A survey: clustering ensembles techniques / R. Ghaemi, M. Sulaiman, H. Ibrahim, N. Mustapha // International Journal of Computer, Electrical, Automation, Control and Information Engineering – 2009. – Vol. 3, N 2. – P. 365-374.
- [8] Hore, P. A scalable framework for cluster ensembles / P. Hore, L.O. Hall, D.B. Goldgof // Pattern Recognition. – 2009. – Vol. 42, N 5. – P. 676-688.
- [9] Kashef, R. Cooperative clustering / R. Kashef, M. Kamel // Pattern Recognition. – 2010. – Vol. 43, N 6. – P. 2315-2329.
- [10] Jia J. Soft spectral clustering ensemble applied to image segmentation / J. Jia, B. Liu, L. Jiao // Frontiers of Computer Science in China. – 2011. – Vol. 5, N 1. – P. 66-78.
- [11] Franek, L. Ensemble clustering by means of clustering embedding in vectorspaces / L. Franek, X. Jiang // Pattern Recognition. – 2014. – Vol. 47, N 2. P. 833-842.
- [12] Zhang, S. Unsupervised evaluation of cluster ensemble solutions / S. Zhang, L. Yang, D. Xie // Proceedings of 7th International Conference on Advanced Computational Intelligence. – IEEE, 2015. – P. 101-106.
- [13] Strehl, A. Cluster ensembles – a knowledge reuse framework for combining multiple partitions / A. Strehl, J. Ghosh // The Journal of Machine Learning Research. – 2003. – Vol. 3. – P. 583-617.
- [14] Filkov, V. Integrating microarray data by consensus clustering / V. Filkov, S. Skiena // International Journal on Artificial Intelligence Tools. – 2004. – Vol. 13, N 4. – P. 863-880.
- [15] Berikov, V. Ensemble clustering based on weighted co-association matrices: Error bound and convergence properties / V. Berikov, I. Pestunov // Pattern Recognition. – 2017. – Vol. 63. – P. 427-436.
- [16] Бериков, В.Б. Построение ансамбля деревьев решений в кластерном анализе / В.Б. Бериков // Вычислительные технологии. – 2010. – Т. 15, № 1. – С. 40-52.
- [17] Пестунов, И.А. Сегментация многоспектральных изображений на основе ансамбля непараметрических алгоритмов кластеризации / И.А. Пестунов, В.Б. Бериков, Ю.Н. Синявский // Вестник Сибирского государственного аэрокосмического университета им. академика М.Ф. Решетнева. – 2010. – № 5(31). – С. 56-64.
- [18] Pestunov, I.A. Ensemble of clustering algorithms for large datasets / I.A. Pestunov, E.A. Kulikova, S.A. Rylov, V.B. Berikov // Optoelectronics, Instrumentation and Data Processing. – 2011. – Vol. 47, N 3. – P. 245-252.
- [19] Pestunov, I.A. Hierarchical clustering algorithms for segmentation of multispectral images / I.A. Pestunov, S.A. Rylov, V.B. Berikov // Optoelectronics, Instrumentation and Data Processing. – 2015. – Vol. 51, N 4. – P. 329-338.
- [20] A Matlab Toolbox for Pattern Recognition [Electronic resource]. – Access mode: <http://www.prtools.org> (06.02.2017).