

УДК 004.932.2:004.93'1

В.А. Гороховатский<sup>1</sup>, М.Д. Дунаевская<sup>2</sup>, В.А. Струненко<sup>2</sup><sup>1</sup> Харьковский учебно-научный институт ГВУЗ «Университет банковского дела», Харьков<sup>2</sup> Харьковский национальный университет радиоэлектроники, Харьков

## ИЗУЧЕНИЕ СВОЙСТВ МЕТОДОВ КЛАСТЕРИЗАЦИИ ПРИМЕНИТЕЛЬНО К МНОЖЕСТВАМ ХАРАКТЕРНЫХ ПРИЗНАКОВ ИЗОБРАЖЕНИЙ

Обсуждаются вопросы анализа свойств методов кластеризации для множеств характерных признаков изображений при распознавании визуальных объектов в системах компьютерного зрения. Исследованы в сравнительном плане методы разностного группирования и *k*-средних, определены погрешности квантования и другие параметры, что позволило установить и оценить возможности их применения. Для конкретных изображений представлены результаты экспериментов по оцениванию точности методов при различном числе кластеров.

**Ключевые слова:** компьютерное зрение, методы структурного распознавания, характерные признаки изображений, кластеризация описания, метод разностного группирования, метод *k*-средних.

### Введение

Структурные методы распознавания визуальных объектов на изображениях сцен в системах компьютерного зрения описывают объект множеством характерных признаков (ХП) – векторов, зафиксированных в координатах ключевых точек изображения и инвариантных к геометрическим преобразованиям объектов [1 – 4]. Один из самых популярных подходов при формировании списка ХП – метод SURF, который включен в ряд пакетов обработки многомерных данных [3]. Детальный анализ пространства ХП показывает, что их влияние на результат распознавания зависит от взаимосвязи внутри эталонов и между разнообразием описаний эталонов.

Самоорганизация структурных признаков путем кластерного представления позволяет вскрыть внутреннюю структуру признакового пространства и свести распознавание к более эффективному сопоставлению, где эталоны описываются векторами, а релевантность эталону характеризуется числовым коэффициентом в виде функции принадлежности [5,6]. Самоорганизация может быть выполнена с использованием ряда методов, наиболее известными из которых есть разностное группирование и *k*-средних [2, 6]. За счет кластеризации описания эталонов трансформируются из пространства «множество дескрипторов» к пространству «числовые векторы», что существенно ускоряет распознавание.

Для успешного осуществления кластеризации требуется инициализация – предварительная обработка данных с целью подготовки начальных условий для функционирования используемых методов обучения. Например, для исполнения кластеризации методом *k*-средних необходимо установить число кластеров и первоначальные значения их центров в пространстве данных. Впоследствии метод обуче-

ния, отталкиваясь от начальных значений, уточняет и завершает группировку объектов. Результаты в значительной степени зависят от начальных установок. Задачи инициализации могут быть решены методами пикового и разностного группирования, которые в то же время можно считать самостоятельными средствами получения знаний [2].

Актуальным представляется изучение свойств и сравнительный анализ эффективности методов кластеризации применительно к множествам структурных признаков, а также анализ особенностей применения кластеризации для этих данных.

Целью статьи есть изучение и сравнение параметров точности методов кластеризации для множеств характерных признаков изображений при применении методов *k*-средних и разностного группирования.

Задачи исследования – изучение особенностей построения методов кластеризации применительно к структурным описаниям изображений, экспериментальное оценивание погрешности и других параметров кластеризации.

### Кластеризации списка структурных признаков методом разностного группирования

Разностное группирование (РГ) считают самостоятельным подходом к кластеризации данных [2]. Оно наиболее эффективно в применении к векторам большой размерности, которая для структурных признаков SURF равна 64 [3]. Рассмотрим суть и особенности подхода РГ применительно к множествам векторов-дескрипторов SURF.

Структурное описание изображения – это конечное множество  $Z \subset R_1^n, R_1^n = \{z | z \in R^n, \|z\| \approx 1\}$ , где  $R_1^n \subset R^n$  – пространство *n*-мерных веществен-

ных векторов с евклидовой нормой, близкой к единице:  $\|z\| = \sqrt{\sum_{k=1}^n z_k^2} \approx 1$  [1]. Выполнение условия нормировки позволяет напрямую применять вектора описания в процедурах обучения без дополнительной обработки.

Метод РГ рассматривает множество обучающих векторов  $Z = \{z_i\}$  как потенциальные центры данных. Кластеры строятся последовательным урезанием исходного множества путем агломерации. Вначале для каждого  $z_i \in Z$  осуществляют вычисление значения пиковой функции (ПФ)

$$D(z_i) = \sum_{j=1}^s \exp \left\{ \frac{-\rho^{2b}(z_i, z_j)}{(\tau/2)^2} \right\}, \quad (1)$$

где  $\rho(z_i, z_j) = \sqrt{\sum_{k=1}^{64} (z_{i,k} - z_{j,k})^2}$  – евклидово расстояние между векторами SURF-признаков;  $\tau$  – константа, которая определяет «сферу соседства», т.е. подмножество векторов  $z_j \neq z_i$  таких, что существенным образом влияют на  $D(z_i)$  и расположены в пределах этой сферы;  $b$  – показатель степени многомерной функции Гаусса [2];  $s = \text{card}(Z)$  – мощность (число элементов) множества векторов  $Z$ .

Идея метода РГ лежит в русле развития метода потенциальных функций как одного из наиболее общих подходов к классификации образов [4]. Значение (1) пропорционально числу векторов, находящихся в окрестности потенциального центра  $z_i$ . Малое значение  $D(z_i)$  свидетельствует о том, что центр располагается в зоне, где сосредоточено незначительное число векторов  $z_j$ . Считается, что коэффициент  $\tau$  практически не оказывает влияние на итоговые пропорции между  $D(z_i)$  для различных  $i$ , поэтому подбор его величины не является критичным [2].

После расчета значений ПФ для всех  $z_i \in Z$  отбирается вектор  $z$ , для которого мера  $D(z)$  оказалась наибольшей. Эта точка фиксируется как первый выбранный центр:  $c_1 = \text{argmax}_{z \in Z} D(z)$ . Перед поиском следующего центра исключаем  $c_1$  из множества  $Z$  и все точки его окрестности в пределах сферы соседства  $\tau$ . Все они образуют первый кластер.

Отбор элементов сферы соседства для кластера  $C_1$  можно осуществить, например, путем анализа близости значений ПФ:

$$C_1 = \{z \in Z \mid |D(c_1) - D(z)| \leq \varepsilon D(c_1)\}, \quad (2)$$

где параметр  $\varepsilon$  функционально связан с  $\tau$  и соответствует доли от значения пика  $D(c_1)$ .

Далее переопределяем ПФ для оставшихся точек:

$$D_{\text{new}}(z_i) = D(z_i) - D(c_1) \exp \left\{ \frac{-\rho^{2b}(z_i, c_1)}{(\tau_1/2)^2} \right\}, \quad (3)$$

где для нового  $D_{\text{new}}$  коэффициент  $\tau_1$  обозначает значение константы, задающей сферу соседства очередного центра, обычно придерживаются условия  $\tau_1 \geq \tau$ . ПФ  $D_{\text{new}}(z_i)$  принимает нулевое значение при  $z_i = c_1$  и близка к нулю для элементов кластера  $C_1$ .

После модификации значений ПФ определяется очередная точка  $z$  с минимальным  $D_{\text{new}}(z)$ ,  $z \in Z, z \notin C_1$ , которая образует следующий центр  $c_2$ . Поиск центра возобновляется после исключения компонентов, включенных в уже отобранные кластеры. Инициализация завершается в момент фиксации всех центров, предусмотренных начальными условиями.

Метод РГ реализует процесс самоорганизации, суть которой – нахождение центров, представляющих множество данных с минимальной погрешностью. Заметим, что метод РГ инвариантен к нумерации множества входных точек, что важно для задач обработки изображений, где последовательность ХП зависит от метода их построения.

Как критерий качества кластеризации (погрешность квантования) употребляют функционал усредненной по числу записей суммы квадратов расстояний между центрами кластеров и включенными в них данными [2]

$$E = \frac{1}{s} \sum_{i=1}^k \sum_{z \in C_i} \rho^2(z, c_i), \quad (4)$$

где  $z \in C_i$  – точка данных кластера  $C_i$  с центром  $c_i$ ,  $\rho(z, c_i)$  – расстояние от точки до центра (как правило – евклидово);  $k$  – число кластеров;  $s$  – мощность обучающего множества  $Z$ .

Значение (4) – это усредненная ошибка в течение  $s$  шагов обучения ( $s$  элементов данных). Выражение (4) можно применить как ко всей базе, так и к отдельному эталону. Если в (4) убрать усреднение – получим величину мгновенной ошибки на очередном шаге обучения. Важно не только непосредственно значение ошибки, а и её изменение в процессе обучения.

В частности, представляет интерес событие стабилизации значений центров  $c_i$ , что соответствует незначительным колебаниям (4).

Методы, нацеленные на минимизацию (4), называют группировкой с минимальной дисперсией [2]. Оптимизация (4) в процессе кластеризации независимо от способа вскрывает внутреннюю структуру пространства данных в форме концентрированных сгущений точек.

### Кластеризация методом k-средних

Метод k-средних (C-means) разбивает множество объектов на заданное число k кластеров, расположенных на возможно больших расстояниях друг от друга [2].

Для сформированного набора центров кластеров  $C = \{c_i\}_{i=1}^k$  аппроксимация произвольного вектора x конкурентным способом означает определение ближайшего к нему вектора  $c_u \in C$ , обычно в евклидовой метрике  $\rho(x, c_i)$ :

$$v = \operatorname{argmin}_{i=1, \dots, k} \{\rho(x, m_i)\} \quad (5)$$

Метод k-средних на практике реализуется в виде алгоритма – вычислительной схемы, которая применяется в ситуации, когда множество Z доступно к началу обучения. Алгоритм располагает центры кластеров (центроиды) так, чтобы средние значения для списков элементов внутри построенных кластеров максимально возможно отличались между собой. Шаги алгоритма:

1) в качестве k начальных центроидов берут произвольные векторы:

$$C = \{m_i\}_{i=1}^k, c_i \in Z;$$

2) для каждого  $i = \overline{1, k}$  путем обучения конкурентного типа (5) формируют список  $N_i \subseteq Z$  тех элементов, для которых ближайшим кодирующим вектором есть  $c_i$ , т.е. составляют подмножества

$$C_i = \{x \in Z \mid \operatorname{argmin}_u \rho(x, c_u) = i\};$$

другой вариант построения списка  $N_i$  – включают в него образцы, находящиеся в пределах области соседства для

$$c_i : N_i = \{x \in Z \mid \rho(x, c_i) \leq \varepsilon_p\},$$

т.е. расположены внутри шара радиуса  $\varepsilon_p$  с центром  $c_i$ ; при этом

$$Z = \cup N_i, N_i \cap N_j = \emptyset;$$

3) в качестве нового значения  $c_i$  вычисляют среднее по списку  $N_i$ , составленному в п. 2:

$$c_i = \sum_{v=1}^{s(i)} x_v / s(i),$$

где  $s(i)$  – мощность  $N_i$ ;

4) повторяют шаги 2-3 несколько раз до достижения сходимости.

Алгоритм особенно эффективен, если начальные значения векторов  $c_i$  предварительно согласованы с обучающим множеством Z. Алгоритм не содержит параметра скорости обучения, поэтому ею управлять или оценивать её в ходе обучения не требуется, и проблем со сходимостью нет. Остановку осуществляют в случае, если на очередной итерации

изменения центров кластеров становятся незначимыми. Здесь применим критерий вида

$$\Delta(C[h+1], C[h]) \leq \varepsilon_C, \quad (6)$$

где  $\Delta$  – некоторая мера различия списков центроидов;  $C[h]$  – значения списка на шаге h итерации;  $\varepsilon_C$  – априорно заданная погрешность.

Как правило, достаточно сделать лишь несколько итераций. Алгоритм k-средних аппроксимирует функцию плотности распределения множества входных образцов по критерию минимума ошибки E. Итерационный алгоритм сходится к локальному минимуму E. Обученный метод k-средних вырабатывает центры кластеров (центроиды), которые представляют собой базисы, в которых можно разложить любое множество входных сигналов.

### Результаты моделирования

В процессе исследований проведено программное моделирование и эксперимент с применением метода разностного группирования, который состоит в задании порога  $\varepsilon$  (соотношение (2)) и исследования характеристик векторов, попавших в полученный диапазон и образовавших кластерное представление.

Рис. 1 демонстрирует множество из 997 векторов XII изображения денежной купюры.




Рис. 1. Изображение с выделенными XII

Вычислена также погрешность квантования для полученного количества кластеров. Полученные результаты предоставлены в табл. 1.

В ходе второго эксперимента осуществлен кластерный анализ и вычисление погрешности квантования для множества признаков изображения рис. 1 с использованием метода k-средних, причем число кластеров выбрано аналогично использованному в методе РГ (табл. 1).

Таблица 1

Характеристики кластеризации

Значение порога $\varepsilon$	Число кластеров	Погрешность E для метода РГ	Погрешность E для метода К-средних
0.1	822	0.078	0.012
0.2	225	0.346	0.062
0.3	50	0.388	0.108
0.4	14	0.382	0.154
0.5	4	0.356	0.199
-	1	0.420	0.250

Експериментальним путем встановлено, що чим більше значення порога  $\varepsilon$ , тем менше формується кількість кластерів в описанні візуального об'єкта і, відповідно, менше буде погрешність квантування (4). Но, в свою чергу, для якісної і ефективною кластеризації необхідно кількість кластерів в межах 5-15 [7]. По цим причинам погрешності квантування 0,382 і 0,154 для обох методів говорять об їх применимости на практиці.

Як видно, погрешність для методу РГ нескільки вище, однак, він формує кластери в умовах неопределенності їх числа, опираючись на значення  $\varepsilon$ .

## Выводы

В процесі проведеного дослідження і експериментів встановлено, що для обох методів кластеризації – різностного групування і к-середніх з збільшенням числа кластерів в межах встановленого діапазону погрешність апроксимації структурних даних зменшується. При цьому для методу к-середніх погрешність нескільки менше, ніж для методу РГ при рівному числі кластерів. Виходячи з отриманих експериментальних даних, можна вважати, що погрешність наближається до 0, якщо число кластерів дорівнює числу векторів в описанні об'єкта. Погрешність максимальна, коли всі вектори утворюють один кластер, при збільшенні числа кластерів погрешність зменшується і наближається до нуля з зростанням числа кластерів.

Наукова новизна дослідження складається в аналізі применимости універсальних методів кластеризації: різностного групування і к-середніх до множин характерних ознак зображень і оцінюванні їх властивостей і характеристик.

Практична цінність роботи – отримання експериментальних оцінок точності кластеризації для списків структурних ознак конкретних зображень при застосуванні методів різностного групування і к-середніх.

Перспективи дослідження пов'язані з оцінюванням ефективності даних методів кластеризації для прикладних задач розпізнавання зображень в базах відеоінформації.

## Список литературы

1. Гороховатский В.А. Структурный анализ и интеллектуальная обработка данных в компьютерном зрении: монография / В.А. Гороховатский. – Х.: Компания СМІТ, 2014. – 316 с.
2. Осовский С. Нейронные сети для обработки информации / С. Осовский [пер. с польского]. – М.: Финансы и статистика, 2002. – 344 с.
3. Bay H. Surf: Speeded up robust features / H. Bay, T. Tuytelaars, L. VanGool // European Conference on Computer Vision. – 2006. – P. 404–417.
4. Duda R.O. Pattern classification / R.O. Duda, P.E. Hart, D.G. Stork. – 2-ed., Wiley, 2000. – 738 p.
5. Прикладная статистика: Классификация и снижение размерности: справ.изд. / С.А. Айвазян, В.М. Бушатаев, И.С. Енюков, Л.Д. Мешалкин; под ред. С.А. Айвазяна. – М.: Финансы и статистика, 1989. – 607 с.
6. Берестовский А.Е. Нейросетевые технологии самообучения в системах структурного распознавания визуальных объектов / А.Е. Берестовский, А.Н. Власенко, В.А. Гороховатский // Реєстрація, зберігання і обробка даних. – 2015. – Т. 17, № 1. – С. 108–120.
7. Gorokhovatsky V.A. Application of Granulation of Feature Descriptions in Structural Image Recognition / V.A. Gorokhovatsky, O.A. Kobylin, Yu.A. Kulikov // Telecommunications and Radio Engineering. – 2015, Vol. 74, No 6. – P. 503–514.

Поступила в редколлегию 30.03.2016

**Рецензент:** д-р техн. наук, проф. Е.П. Пулятин, Харьковский национальный университет радиоэлектроники, Харьков.

## ВІВЧЕННЯ ВЛАСТИВОСТЕЙ МЕТОДІВ КЛАСТЕРИЗАЦІЇ СТОСОВНО ДО МНОЖИН ХАРАКТЕРНИХ ОЗНАК ЗОБРАЖЕНЬ

В.О. Гороховатський, М.Д. Дунаєвська, В.А. Струненко

*Обговорюються питання аналізу властивостей методів кластеризації для множин характерних ознак зображень при розпізнаванні візуальних об'єктів в системах комп'ютерного зору. Досліджено в порівняльному плані методи різницевого групування і к-середніх, визначені похибки квантування і інші параметри, що дозволило встановити і оцінити можливості їх застосування. Для конкретних зображень представлені результати експериментів з оцінювання точності методів при різній кількості кластерів.*

**Ключові слова:** комп'ютерний зір, методи структурного розпізнавання, характерні ознаки зображень, кластеризація опису, метод різницевого групування, метод к-середніх.

## STUDY PROPERTIES OF CLUSTERING METHODS RELATIVE TO THE SET OF CHARACTERISTIC SIGNS OF IMAGES

V.A. Gorokhovatsky, M.D. Dunaevskaya, V.A. Strunenko

*Discussing problems of analyzing the properties of clustering methods to set specific image features in recognizing visual objects in computer vision systems. Was studied in comparative terms and methods of grouping the difference to the average-defined quantization errors and other parameters, which allowed to establish and assess the possibility of their application. For specific image shows the results of experiments on the estimation accuracy of methods for different numbers of clusters.*

**Keywords:** computer vision, structural methods of recognition, key characteristics of the images, clustering description, differential clustering method, k-average method.