

УДК 004.932.2

СРАВНЕНИЕ ДЕТЕКТОРОВ ОСОБЫХ ТОЧЕК ИЗОБРАЖЕНИЙ И ОЦЕНКА ИХ СТАТИСТИЧЕСКИХ ХАРАКТЕРИСТИК

© А. К. Шакинов

*Институт автоматизации и электрометрии СО РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 1
E-mail: adil.shakenov@ngs.ru*

Проведено сравнение детекторов особых точек: BRISK, AKAZE и ORB. В серии экспериментов на наборе из 10000 изображений оценены характеристики эффективности алгоритмов поиска особых точек: доля правильно найденных положений особых точек, доля правильно установленных соответствий, количество соответствий при сопоставлении двух произвольно взятых изображений. Рассчитана зависимость среднего количества ложных соответствий от величины допустимой близости дескрипторов. Построены графики распределения числа правильных и ложных соответствий.

Ключевые слова: детекторы и дескрипторы особых точек, поиск и сопоставление изображений, соответствия на изображениях, BRISK, AKAZE, ORB.

DOI: 10.15372/AUT20210102

Введение. Особые точки изображения широко применяются в различных задачах компьютерного зрения. Например, в работах [1–5] они использованы для трёхмерной реконструкции объектов по серии фотографий. В [6] рассмотрено применение особых точек для обнаружения объектов неприродного происхождения, а в [7] они использованы для сшивки панорамных аэрофотоснимков. Особые точки изображений также применяются для распознавания объектов [8–11], поиска и распознавания людей [12, 13] и в других задачах. Некоторые классические детекторы особых точек, такие как ORB [14], FAST [15], BRISK [16], AKAZE [17] распространяются в виде открытого исходного кода и доступны в библиотеке OpenCV. Из-за большого разнообразия детекторов возникает вопрос, какие из них и в каких случаях работают лучше, а какие — хуже.

Множество работ посвящено сравнению детекторов. В то же время при анализе большого количества публикаций не удалось найти данные о распределении числа правильных и ложных соответствий при сопоставлении пары изображений. Кроме того, все рассмотренные сравнения детекторов и их исследования были проведены на малом количестве изображений (не более 200), из-за чего построение таких распределений не представлялось возможным. При этом априорное знание распределений числа соответствий, получаемых при работе детекторов особых точек, является важным для создания большого количества алгоритмов, устанавливающих соответствие изображений или их фрагментов, поскольку позволяет предсказать количество ложных и истинных соответствий и учесть эту информацию в процессе проектирования и выбора того или иного подхода к решению задачи. Особенно важным является знание полученного в данной работе распределения числа ложных срабатываний, потому что оно не зависит от характера искажений исходного и сопоставляемого изображений.

Сравнение по времени работы и количеству находимых особых точек детекторами ORB, FAST, BRISK и AKAZE было проведено в [18]. В экспериментах было рассмотрено 90 изображений.

В [19] представлено сравнение эффективности работы детекторов в паре с различными дескрипторами. Рассмотрены комбинированные алгоритмы, содержащие детекторы и

дескрипторы SIFT, SURF, ORB, BRISK, KAZE и AKAZE, реализованные отдельно детекторы FAST, AGAST и STAR и дескрипторы BRIEF, DAISY, FREAK, LUCID и LATCH. Сравнение проводилось на базе 48 изображений.

В исследовании [20] проверяли эффективность детекторов SIFT, SURF, BRISK, ORB, KAZE и AKAZE при сопоставлении 5 изображений. Эффективность определялась количеством найденных соответствий и временем работы алгоритмов.

Работа [21] была посвящена сравнению дескрипторов DAISY, BRISK, AKAZE, LATCH, SIFT и SURF применительно к стереовидению. В ходе исследования получено количество найденных соответствий, количество правильных соответствий (в процентах) и установлено время работы алгоритмов. Алгоритмы сравнивались по 36 изображениям.

Исследование [22] отличается от вышерассмотренных тем, что в нём, помимо сравнения детекторов SIFT, SURF (версия со 128 и 64 длинами дескрипторов), KAZE, AKAZE, ORB и BRISK, измерялось количество неправильно найденных соответствий (их поиск проводился с помощью метода RANSAC). Эксперименты были поставлены на 12 изображениях.

В [13] был разработан алгоритм поиска и слежения за объектом, основанный на детектировании особых точек. Для выбора лучшего для данной задачи детектора было проведено сравнение времени поиска, числа соответствий и правильных соответствий детекторов AKAZE, SIFT, SURF и ORB. Так как предложенный алгоритм рассчитан для работы с видеоизображениями в реальном времени, эксперименты были поставлены на 7 видеорядах.

В [23] алгоритмы сравниваются на большом наборе данных, но алгоритм AKAZE в этой работе не рассматривается.

Большинство исследований по этой теме проводилось на основе данных маленькой выборки. Оценки качества работы детекторов на таких выборках нельзя считать достоверными из-за широкого разброса характеристик изображений, регистрируемых при съёмке произвольных сцен. Различие изображений обусловлено наличием разных предметов, текстур и условий съёмки. Таким образом, для того чтобы учесть всевозможные различия регистрируемых изображений, необходимо использование больших массивов данных при оценке характеристик детекторов особых точек. Кроме того, для оценки распределения количества соответствий на изображениях необходимо количество изображений, в несколько раз превосходящее число точек оцениваемого распределения. В представленной работе описано сравнение детекторов BRISK, AKAZE и ORB, проведённое на достаточно большом (10 000) количестве изображений. Это позволило построить распределение числа правильно и неправильно найденных соответствий.

Постановка задачи. Необходимо разработать метод сравнения и оценки статистических характеристик детекторов особых точек изображений и провести оценку распределения числа правильных и ложных соответствий при сопоставлении пары искажённых изображений одной сцены.

Алгоритм оценки эффективности детекторов. Для сравнения детекторов был предложен алгоритм, позволяющий проводить подсчёт правильных соответствий между особыми точками изображения и его изменённой копии. Для этого к изображению, подаваемому на вход, применяется заданное искажение, затем производится поиск особых точек на обоих изображениях, а далее между этими двумя множествами особых точек ищутся соответствия. Схема алгоритма представлена на рис. 1.

Большой класс искажений описывает модель

$$I_2(x, y) = B_k * I_1(F(x, y)),$$

где I_1 — исходное изображение, I_2 — искажённое изображение, B_k — ядро размытия изображения, F — функция геометрического искажения, а «*» — операция свёртки.

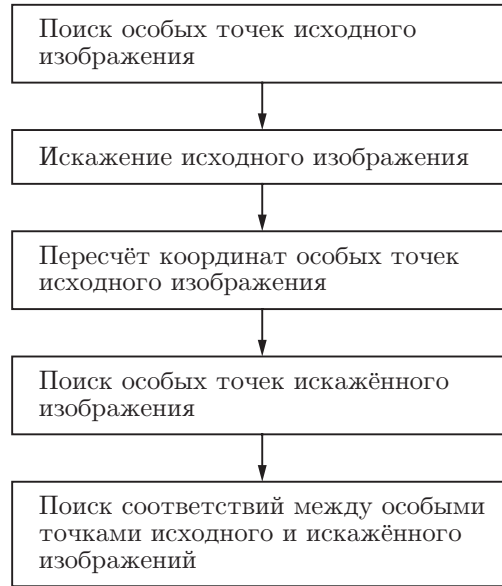


Рис. 1. Схема алгоритма подсчёта правильных соответствий

Использовалось ядро размытия вида

$$B_k = \frac{1}{k^2} J,$$

где k — размер ядра размытия, а J — матрица единиц размера $k \times k$.

Пусть K_1 — множество особых точек исходного изображения, K_2 — множество особых точек искажённого изображения. Так как параметры искажения известны и являются входными данными алгоритма, то можно построить \tilde{K}_2 — множество особых точек изображения, координаты которых получены из точек K_1 . Пусть $\tilde{K}_2 = \{F(p) \mid p \in K_1\}$, т. е.

$$\tilde{p} = F(p) = A \begin{pmatrix} x \\ y \end{pmatrix},$$

где A — матрица преобразования; p — особая точка исходного изображения; \tilde{p} — точка, в которую под преобразованием F переходит точка p ; (x, y) — координаты точки p .

Поворот и изменение масштаба изображения определяется матрицей

$$A = \begin{pmatrix} \gamma & \delta \\ -\delta & \gamma \end{pmatrix},$$

где $\gamma = scale \cdot \cos(angle)$, $\delta = scale \cdot \sin(angle)$, $scale$ — множитель изменения масштаба изображения, $angle$ — угол, на который изображение поворачивается.

Ключевые точки $a \in K_1$ и $b \in K_2$ с дескрипторами d_1 и d_2 можно считать соответствующими друг другу, если близки их дескрипторы, т. е. $\|d_1, d_2\| < T_d$, и при этом с допустимой погрешностью совпадает их положение на исходном и искажённом изображениях: $\|\tilde{a}, b\|_2 < T_g$, где $\tilde{a} \in \tilde{K}_2$ — точка, прообразом которой является a ; T_d и T_g — пороги, определяющие точность. Обозначим и для этой точки G множество точек, для которых нашлись в том же положении точки на искажённом изображении, т. е. G — это множество точек $a \in K_1$ исходного изображения таких, что существует точка $b \in K_2$ искажённого изображения и выполняется неравенство $\|\tilde{a}, b\|_2 < T_g$.



Рис. 2. Правильные соответствия изображения



Рис. 3. Ложное соответствие на двух случайных изображениях

После проверки совпадения положений точек и близости их дескрипторов, выполненной для всех пар точек исходного и искажённого изображений, получается множество правильных соответствий между особыми точками рассматриваемой пары изображений. Обозначим множество правильных соответствий как S .

На рис. 2 приведён пример множества S . Точками показаны особые точки изображения, а линиями — соответствия между ними.

Важной характеристикой детекторов является величина ошибочно находимых соответствий, которую можно оценить, подсчитав математическое ожидание количества установленных соответствий между двумя различными случайно выбранными изображениями. Фрагменты разных изображений могут быть похожи, но в контексте задачи поиска изображений соответствия, найденные между двумя случайными изображениями, являются ложными. Множество ложных соответствий, определённых алгоритмом при сопоставлении исходного и случайно выбранного изображений, будет обозначаться \bar{S} . На рис. 3 приведён пример множества \bar{S} .

Для проведения экспериментов была написана программа, реализующая предложенный алгоритм.

Экспериментальные результаты. Эксперименты были проведены на базе изображений, сформированной из фотографий Creative Commons, представленных на сайте Flickr [24]. Для оценки количества правильных соответствий, находимых детекторами, в экспериментах использовались 10 000 изображений. Для подсчёта ложных соответствий был взят дополнительный набор, также состоящий из 10 000 изображений.

Параметры детекторов подобраны таким образом, чтобы среднее значение числа особых точек на исходных изображениях было приблизительно одинаковым. Среднее значение числа точек, найденных на исходных изображениях при применении детектора BRISK, составляло 419,4, детектора AKAZE — 431,9, детектора ORB — 432,9.

В табл. 1, 2 и 3 приведены результаты экспериментов, проведённых с применением детекторов BRISK, AKAZE и ORB. При искажении изображений использовались параметры изменения геометрии $angle = 40$, $scale = 3,8$ и размытие с ядром размера 13×13 пикселей. С учётом увеличения размера искажённого изображения порог T_g был выбран равным 8,7 пикселя. Столбцы таблиц:

- T_d — величина порога близости дескрипторов;
- $\text{Avg}(|G|/|K_1|)$ — среднее значение отношения числа особых точек, найденных в тех же позициях после искажения без учёта близости дескрипторов (множество G), к числу особых точек исходного изображения;
- $\text{Avg}(|C|)$ — среднее количество правильно найденных соответствий;
- $\text{Avg}(|C|/|K_1|)$ — среднее значение отношения количества точек из множества правильных соответствий C к числу особых точек исходного изображения;
- $\text{Avg}(|\bar{F}|)$ — среднее количество ложных соответствий;
- Runtime — время работы программы в секундах.

Из таблиц видно, что детектор AKAZE находит в несколько раз больше правильных соответствий, чем BRISK, а ORB находит меньше всего правильных соответствий. При этом время работы детекторов BRISK и ORB отличается незначительно, а продолжительность работы детектора AKAZE превышает продолжительность работы детекторов BRISK и ORB более чем в 4 раза. Построенная зависимость среднего количества ложных соответствий от величины допустимой близости дескрипторов позволяет подобрать требуемый размер близости дескриптора для конкретной задачи.

В ходе экспериментов было оценено распределение числа пар соответствующих исходных и искажённых изображений по параметру найденных на них правильных соответствий. Аналогичное распределение было оценено также для пар случайно выбранных изображений. Полученные распределения приведены на графиках (рис. 4, 5, 6). По оси абсцисс указано количество соответствий на паре изображений, а по оси ординат — процент пар изображений относительно обработанного массива данных. Представленные распределения получены с порогами близости дескрипторов T_d , равными 70 и 100 для алгоритмов BRISK и AKAZE. Данные значения были выбраны из следующих соображений. С одной стороны, для установления большего количества соответствий необходимо брать по возможности больший порог допустимой близости дескрипторов. С этой точки зрения пороговое значение $T_d = 100$ представляет максимально разумное большое значение порога, при этом очевидно, что такое значение порога даёт неудовлетворительные результаты. Эксперименты с пороговым значением $T_d = 70$ приведены из-за того, что при его использовании сохраняется достаточное количество соответствий особых точек и при этом можно эффективно отличить пары искажённых изображений одной и той же сцены от двух случайно выбранных изображений. Необходимо также отметить, что с практической точки зрения сопоставление двух изображений на основе количества совпадающих особых точек, как правило, является только первым шагом при построении алгоритма сопоставления изображений. Поэтому целесообразно брать достаточно высокие значения порога близости особых точек (например, $T_d = 70$), чтобы сохранить возможность построения

Таблица 1

Результаты вычислений при использовании алгоритма BRISK

T_d	Avg ($ G / K_1 $)	Avg ($ C $)	Avg ($ C /K_1$)	Avg ($ \bar{F} $)	Runtime
30	0,21	4,55	0,02	0	1991
40	0,21	9,26	0,03	0,0002	2079
50	0,21	14,45	0,05	0,0033	4159
60	0,21	19,63	0,06	0,0342	6103
70	0,21	24,50	0,08	0,2146	8038
80	0,21	29,10	0,09	0,9578	9979
90	0,21	33,47	0,1	3,0414	11935
100	0,21	37,58	0,11	7,7756	13915
110	0,21	41,47	0,12	17,0695	15923

Таблица 2

Результаты вычислений при использовании алгоритма AKAZE

T_d	Avg ($ G / K_1 $)	Avg ($ C $)	Avg ($ C /K_1$)	Avg ($ \bar{F} $)	Runtime
30	0,39	50,33	0,12	0	9843
40	0,39	79,4	0,18	0,0004	9489
50	0,39	97,51	0,22	0,0021	19026
60	0,39	109,03	0,24	0,0363	28541
70	0,39	117,54	0,26	0,3045	38623
80	0,39	124,76	0,27	1,6435	48348
90	0,39	131,39	0,29	6,6894	57901
100	0,39	137,68	0,30	20,456	67461
110	0,39	143,6	0,31	47,7018	78267

Таблица 3

Результаты вычислений при использовании алгоритма ORB

T_d	Avg ($ G / K_1 $)	Avg ($ C $)	Avg ($ C /K_1$)	Avg ($ \bar{F} $)	Runtime
30	0,34	7,89	0,02	0,0014	2075
40	0,34	15,72	0,04	0,1242	1996
50	0,34	24,58	0,06	2,8097	3964
60	0,34	34,32	0,08	28,8772	5938
70	0,34	44,99	0,1	134,774	7950
80	0,34	57,05	0,13	313,842	9983
90	0,34	71,11	0,16	416,68	12043
100	0,34	87,18	0,2	432,273	14101
110	0,34	104,32	0,24	432,823	16170

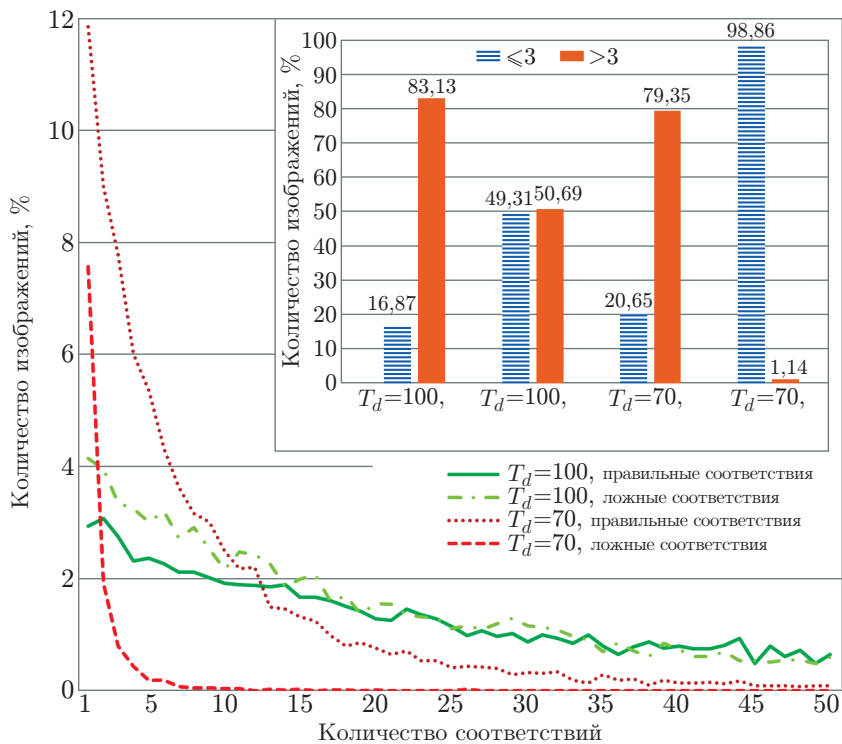


Рис. 4. Распределение числа правильных и ложных соответствий при использовании алгоритма BRISK




Рис. 5. Распределение числа правильных и ложных соответствий при использовании алгоритма AKAZE




Рис. 6. Распределение числа правильных и ложных соответствий при использовании алгоритма ORB

проверок их совпадения на основе других критериев. Исходя из аналогичных соображений для алгоритма ORB приведены аналогичные зависимости, полученные при величинах порога T_d , равных 40 и 60. Подсчитано количество изображений:

- с числом правильных соответствий меньше или равным 3;
- с числом правильных соответствий больше 3;
- с числом ложных соответствий меньше или равным 3;
- с числом ложных соответствий больше 3.

Эти значения на рис. 4, 5, 6 показаны в виде дополнительных гистограмм. Порог, равный трём соответствиям особых точек на паре изображений, был выбран из-за того, что при дальнейшем уменьшении количества соответствий происходит резкое падение качества сопоставления изображений. Кроме того, наличие минимум 3 соответствия особых точек позволяет оценить аффинное преобразование, связывающее пару изображений.

На графиках видно, что для алгоритмов BRISK и AKAZE при пороге близости дескрипторов, равном 70, происходит разделение классов искажённых и случайно выбранных изображений. В то же время при пороге близости дескрипторов, равном 100, эти классы практически не разделяются.

При правильно выбранном значении порога близости дескрипторов применение детекторов особых точек даёт приемлемые результаты. В проведённых экспериментах наилучший результат был показан алгоритмом ORB, но этот детектор недостаточно стабилен для преобразований с большими значениями изменения масштаба и более сильным размытием. Характерный вид распределения количества соответствий с выраженным пиком объясняется отличным подходом к количеству генерируемых особых точек, реализованным в этом алгоритме. В алгоритмах BRISK и AKAZE для регулирования количества точек на вход передаётся порог, характеризующий меру отличия точки на изображении. Это приводит к тому, что на большом количестве изображений выделяется малое количество особых точек и, как следствие, малое или нулевое количество соответствий, что

отображается ростом количества изображений при малом количестве соответствий. В алгоритме ORB на вход передаётся количество особых точек, которое должен найти алгоритм. В проведённых экспериментах передавалось значение, равное 500 точкам. В случае если алгоритму не удастся найти требуемое количество точек, он возвращает меньшее количество. Однако ориентация на нахождение заданного количества точек приводит к тому, что изображений с малым количеством точек не так много, как при рассмотрении предыдущих алгоритмов. Это приводит к появлению пика правильно найденных соответствий в положительной зоне. Как видно из гистограмм, алгоритм ORB даёт ложноположительные $4,8 \cdot 10^{-3}$ и ложноотрицательные $6,53 \cdot 10^{-2}$ ошибки. Для алгоритма AKAZE ошибка ложного срабатывания составила $1,22 \cdot 10^{-2}$, пропуска соответствия — $6,39 \cdot 10^{-2}$, а для BRISK — $1,14 \cdot 10^{-2}$ и 0,2 соответственно. Приведённые данные позволяют качественно оценить работу детекторов. Эти результаты получены при фиксированном искажении и наборе параметров детекторов и поэтому не позволяют сделать вывод об однозначном преимуществе того или иного детектора. При этом можно констатировать, что для ряда случаев алгоритм ORB даёт лучшие результаты и может быть рекомендован для рассмотрения при решении практических задач. Хотя этот уровень ошибок является разумным и может быть приемлемым для некоторых приложений, для значительного числа задач вероятность ошибки в диапазоне 0,06–0,2 недостаточно низка. В этом случае должен быть разработан алгоритм дополнительной обработки использованных характерных точек.

Заключение. В данной работе приведены результаты оценки эффективности наиболее известных методов поиска особых точек изображений и вычисления их дескрипторов, а также рассчитана зависимость среднего количества ложных соответствий от величины допустимой близости дескрипторов. Построены графики распределения числа найденных соответствий между исходным изображением и его искажённой копией, а также между двумя случайными изображениями. Анализ полученных распределений показывает, что если класс искажений определяется аффинным преобразованием и размытием изображений, то дескрипторы особых точек можно использовать, чтобы установить, состоит ли пара из исходного и искажённого изображений одной и той же сцены либо содержит разные. Однако вероятности ошибок при таком подходе достаточно высоки, и для их снижения необходимо использовать дополнительную обработку рассматриваемых особых точек.

Финансирование. Работа выполнена при поддержке Министерства высшего образования и науки РФ (государственная регистрация № АААА-А17-117052410034-6).

СПИСОК ЛИТЕРАТУРЫ

1. Nagara K., Roth H. R., Nakamura S. et al. Micro-CT guided 3D reconstruction of histological images // Lect. Notes Comput. Sci. 2017. **10530**. P. 93–101.
2. Yamada K., Kimura A. A performance evaluation of keypoints detection methods SIFT and AKAZE for 3D reconstruction // Proc. of the Intern. Workshop on Advanced Image Technology. Chiang Mai, Thailand, 7–9 Jan. 2018. P. 1–4.
3. Hlubik J., Kamencay P., Hudec R. et al. Advanced point cloud estimation based on multiple view geometry // Proc. of the 28th Intern. Conference Radioelektronika. Prague, Czech Republic, 19–20 Apr. 2018. P. 1–5.
4. Lou L., Liu Y., Sheng M. et al. A cost-effective automatic 3D reconstruction pipeline for plants using multi-view images // Lect. Notes Comput. Sci. 2014. **8717**. P. 221–230.
5. Milosavljevic S., Freysinger W. Quantitative measurements of surface reconstructions obtained with images a surgical stereo microscope // Tagungsband 15 Jahrestagung der Deutschen Gesellschaft für Computer und Roboterassistierte Chirurgie. Bern, Deutschland, 29 Sept.–1 Oct. 2016. Uelvesbüll: Der Andere Verlag. S. 47–52.

6. **Борзов С. М., Нежевенко Е. С., Потатуркин О. И.** Поиск объектов не природного происхождения с использованием их структурных особенностей // *Автометрия*. 2010. **46**, № 5. С. 36–42.
7. **Фаворская М. Н., Пахирка А. И., Зотин А. Г., Буряченко В. В.** Создание панорамных аэрофотоснимков на основе многополосного смешивания // *Автометрия*. 2018. **54**, № 3. С. 24–31. DOI: 10.15372/AUT20180303.
8. **Nabiyeu V. V., Yilmaz S., Günay A. et al.** Shredded banknotes reconstruction using AKAZE points // *Forensic Sci. Int.* 2017. **278**. P. 280–295.
9. **Kajiwara Y., Nakamura M., Kimura H.** Classification of single-food images by combining local HSV-AKAZE features and global features // *IRJCS*. 2015. **2**, № 1. P. 12–17.
10. **Taran O., Rezaeifar S., Dabrowski O. et al.** PharmaPack: Mobile fine-grained recognition of pharma packages // *Proc. of the 25th Europ. Signal Processing Conference*. Kos, Greece, 28 Aug.–2 Sept. 2017. P. 1917–1921.
11. **Свитов Д. В., Куликов В. А., Косых В. П.** Обнаружение подозрительных предметов на основе анализа рентгенографических изображений человека // *Автометрия*. 2017. **53**, № 2. С. 72–78. DOI: 10.15372/AUT20170208.
12. **Ishikoori Y., Madokoro H., Sato K.** Semantic position recognition and visual landmark detection with invariant for human effect // *Proc. of the Intern. Symposium on System Integration*. Taipei, Taiwan, 11–14 Dec. 2017. P. 657–662.
13. **Lu X., Li D.** Research on target detection and tracking system of rescue robot // *Proc. of the Chinese Automation Congress*. Jinan, China, 20–22 Oct. 2017. P. 6623–6627.
14. **Rublee E., Rabaud V., Konolige K., Bradski G.** ORB: An efficient alternative to SIFT or SURF // *Proc. of the Conference on Computer Vision*. Barcelona, Spain, 6–13 Nov. 2011. P. 2564–2571.
15. **Rosten E., Drummond T.** Machine learning for high-speed corner detection // *Lect. Notes Comput. Sci.* 2006. **3951**. P. 430–443.
16. **Leutenegger S., Chli M., Siegwart R. Y.** BRISK: Binary robust invariant scalable keypoints // *Proc. of the Intern. Conference on Computer Vision*. Barcelona, Spain, 6–13 Nov. 2011. P. 2548–2555.
17. **Alcantarilla P. F., Nuevo J., Bartoli A.** Fast explicit diffusion for accelerated features in nonlinear scale spaces // *IEEE Trans. Patt. Anal. Mach. Intell.* 2011. **34**, N 7. P. 1281–1298.
18. **Veres O., Rusyn B., Sachenko A., Rishnyak I.** Choosing the method of finding similar images in the reverse search system // *CEUR Workshop Proceedings*. 2018. **2136**. P. 99–107.
19. **Bureš L., Müller L.** Selecting keypoint detector and descriptor combination for augmented reality application // *Lect. Notes Comput. Sci.* 2016. **9811**. P. 604–612.
20. **Noble F. K.** Comparison of OpenCV’s feature detectors and feature matchers // *Proc. of the 23rd Intern. Conference on Mechatronics and Machine Vision in Practice (M2VIP)*. Nanjing, China, 28–30 Nov. 2016. P. 1–6.
21. **Satnik A., Hudec R., Kamencay P. et al.** A comparison of key-point descriptors for the stereo matching algorithm // *Proc. of the 26th Int. Conference on Radioelektronika*. Kosice, Slovakia, 19–20 Apr. 2016. P. 292–295.
22. **Tareen S. A. K., Saleem Z.** A comparative analysis of SIFT, SURF, KAZE, AKAZE, ORB, and BRISK // *Proc. of the Intern. Conference on Computing, Mathematics and Engineering Technologies*. Sukkur, Pakistan, 3–4 March 2018. P. 1–10.
23. **Lenc K., Vedaldi A.** Large scale evaluation of local image feature detectors on homography datasets // *Proc. of the 29th Intern. Conference on British Mach. Vis.* Newcastle, United Kingdom, 3–6 Sept. 2018.
24. **База изображений MIRFLICKR.** URL: <http://press.liacs.nl/mirflickr/> (дата обращения: 10.02.2016).

Поступила в редакцию 08.07.2020

После доработки 28.08.2020

Принята к публикации 12.10.2020