

УДК 004.9

## ИДЕНТИФИКАЦИЯ УЧАСТКОВ ПОВЕРХНОСТИ ОТДЕЛЬНЫХ ОБЪЕКТОВ НА 2D-ИЗОБРАЖЕНИИ В ЗАДАЧАХ ОЦЕНКИ СОСТОЯНИЯ ИХ МАССОВОГО КОЛИЧЕСТВА

Д.С. Остапов<sup>a</sup>, С.В. Усатиков<sup>b</sup>

<sup>a</sup> Кубанский государственный технологический университет, Краснодар, 350072, Российская Федерация

<sup>b</sup> Кубанский государственный университет, Краснодар, 350040, Российская Федерация

Адрес для переписки: krasnodar93@mail.ru

### Информация о статье

Поступила в редакцию 22.04.17, принята к печати 07.06.17

doi: 10.17586/2226-1494-2017-17-4-685-693

Язык статьи – русский

**Ссылка для цитирования:** Остапов Д.С., Усатиков С.В. Идентификация участков поверхности отдельных объектов на 2D-изображении в задачах оценки состояния их массового количества // Научно-технический вестник информационных технологий, механики и оптики. 2017. Т. 17. № 4. С. 685–693. doi: 10.17586/2226-1494-2017-17-4-685-693

### Аннотация

Рассмотрено математическое обеспечение подсистемы идентификации и оценки состояния участков поверхности массового количества материальных объектов как генеральной совокупности. Предлагаемое решение дополняет функциональные возможности системы компьютерного зрения распознавания типов и видов объектов на 2D-изображении. Предложены основанные на критерии Пирсона алгоритмы качественной и количественной оценки состояния каждого единичного материального объекта (элемента генеральной совокупности), чувствительные к деталям их видимой поверхности. Показана эффективность подсистемы на различных изображениях. Рассмотрены возможности уменьшения времени обработки видеокadra в рабочем режиме системы компьютерного зрения (СКЗ) за счет снижения вычислительной сложности алгоритмов и повышения производительности последовательных вычислений и организацией параллельных вычислений. Точность рассчитывалась как отношение количества верно идентифицированных СКЗ состояний участков поверхности к их общему количеству. На изображениях с инспекционного конвейера с фруктовым сырьем СКЗ имеет точность 98,5%; на объектах в виде таблеток аспирина точность 93,2%, а на объектах зерновой массы риса – 95,4%.

### Ключевые слова

системы компьютерного зрения, подсистема идентификации состояния, массовое количество объектов

## SEGMENTAL SURFACES IDENTIFICATION OF SEPARATE OBJECTS ON 2D-IMAGE IN TASKS OF THEIR MASS QUANTITY CONDITION ASSESSMENT

D.S. Ostapov<sup>a</sup>, S.V. Usatikov<sup>b</sup>

<sup>a</sup> Kuban State Technological University, Krasnodar, 350072, Russian Federation

<sup>b</sup> Kuban State University, Krasnodar, 350040, Russian Federation

Corresponding author: krasnodar93@mail.ru

### Article info

Received 22.04.17, accepted 07.06.17

doi: 10.17586/2226-1494-2017-17-4-685-693

Article in Russian

**For citation:** Ostapov D.S., Usatikov S.V. Segmental surfaces identification of separate objects on 2D-image in tasks of their mass quantity condition assessment. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2017, vol. 17, no. 4, pp. 685–693 (in Russian). doi: 10.17586/2226-1494-2017-17-4-685-693

### Abstract

We consider software of identification and assessment subsystem for condition of segmental surfaces of mass quantity of single material objects (as general population). Proposed solution supplements functionality of computer vision system (SCV) for recognition of types and sorts of objects on 2D-image. We suggest the algorithms of quantitative and qualitative assessment of each single material object condition (the element of general population) sensitive to details of their visible surface based on Pearson's criterion. Efficiency of a subsystem on different images is shown. We consider the possibilities of time reduction of video picture processing in an operating mode of computer vision system due to the decrease in computing complexity of algorithms and the increase in productivity of consecutive calculations and the organization of parallel

calculations. The accuracy was calculated as the ratio of the number of correctly identified computer vision system states of the segments to their total number. It was revealed that on the images from the inspection conveyor with fruit raw materials, the SCV has an accuracy of 98.5% on the given type of objects. On the objects in the form of aspirin tablets, system of computer vision has accuracy of 93.2%, and at the objects of rice grain mass it is 95.4%.

#### Keywords

computer vision systems, state identification subsystem, objects mass quantity

#### Введение. Постановка задачи

Современное управление технологическим процессом, контроль качества продукции и пр. включают системы поддержки принятия решений, требующие все новой функциональности систем компьютерного зрения (СКЗ) [1–3]. Перспективные СКЗ в задачах пищевой и зерноперерабатывающей промышленности исследуются многочисленными коллективами, включая корпорации Buhler, Cognex и др. В таких ситуациях, как фотосепарация и инспекция на конвейерах, снабженных CCD- (ПЗС-) камерами, необходимо техническое решение, позволяющее проводить анализ видеоизображения множественного количества объектов (как генеральной совокупности), когда в каждом кадре присутствует большое количество единичных объектов (элементов генеральной совокупности) на относительно однородном рабочем фоне. Как генеральная совокупность может выступать зерновая масса риса или пшеницы, фруктовое или овощное сырье, готовая конвейерная продукция. Каждый элемент генеральной совокупности разного типа и вида – зерновки риса определенного сорта, яблоки, лекарственные таблетки, возможные посторонние примеси или нежелательные фракции – может находиться в разных существенных для технологических целей состояниях: например, рис длиннозерный сорта кураж, стекловидный, с пятнами меловыми или порченными разного размера, яблоко красное сорта Red Delicious с пятнами зеленого экзокарпия, чашечкой и плодоножкой. Актуальным является обеспечение такой функциональности СКЗ, дополнительной к распознаванию типов и видов объектов, как качественная и количественная оценка состояния каждого единичного объекта, чувствительная к деталям их видимой поверхности, при высокой вариабельности их свойств, и сбор такой информации в целом по выборке с большим числом этих объектов путем анализа видеоизображений с CCD-камер. Входной информацией является пиксельная матрица, в которой каждый пиксель кодируется 3D-точкой в цветовой шкале LAB.

В работах [3–5] предложена общая структура СКЗ требуемой функциональности: декомпозиция на подсистемы обработки мгновенных 2D-изображений и набора разноракурсных снимков (в случае не одной, а нескольких видеокамер), режимы обучения системы и рабочий, сегментация изображений и идентификация сегментов, их качественная и количественная оценки. Подсистема идентификации необходима в рабочем режиме (рис. 1, а), в ее задачи входит оценка состояния участков поверхности массового количества единичных материальных объектов, основанная на чувствительной к деталям видимой поверхности оценке состояния каждого единичного материального объекта. Определение типа и вида объекта происходит по алгоритмам [3] и в данной работе не рассматривается. Аналогичное по решаемым задачам математическое обеспечение описано в [6–14]. В результате настоящей работы подсистема идентификации (рис. 1, б) должна для каждого найденного на изображении объекта уже распознанного типа и вида отнести каждый пиксель к определенной группе пикселей, идентифицируемой как состояние из заданного обучающего набора (рис. 2), диктуемого целями технологического процесса. Требуется также провести количественную оценку этой группы (ее геометрические размеры, площадь) и собрать статистику по всем распознанным объектам.

Алгоритмы подсистемы могут быть основаны на нейросетевых (НС) методах, байесовском классификаторе, методе Viola-Jones и др. [6–14]. Для данной ситуации применение каждого метода связано с некоторыми трудностями. НС-классификация требует снижения размерности входного и выходного вектора, здесь равной утроенному числу пикселей. Байесовский классификатор при длительном обучении в рабочем режиме эффективен по скорости, но имеет низкую точность. Метод Виола–Джонса, эффективный при выделении лиц на видеокадре, черт лица и мимики, может потерять эффективность в ситуации большого числа выделяемых объектов на видеокадре и большого числа мелких участков их поверхностей в разных состояниях.

В настоящей работе рассмотрено математическое обеспечение подсистемы идентификации и оценки состояния участков поверхности массового количества единичных материальных объектов, дополняющее функциональность СКЗ-распознавания типов и видов объектов на 2D-изображении при высокой вариабельности внутри их типов и видов и близости самих видов. Предложены основанные на критерии Пирсона алгоритмы качественной и количественной оценки состояния каждого единичного материального объекта, чувствительные к деталям их видимой поверхности. Показана эффективность подсистемы на изображениях с зерновой массой риса, фруктовым сырьем и фармакологической продукцией. Рассмотрены возможности уменьшения времени обработки видеокадра в рабочем режиме СКЗ за счет снижения вычислительной сложности алгоритмов, повышения производительности узких мест последовательных вычислений и организации параллельных вычислений.

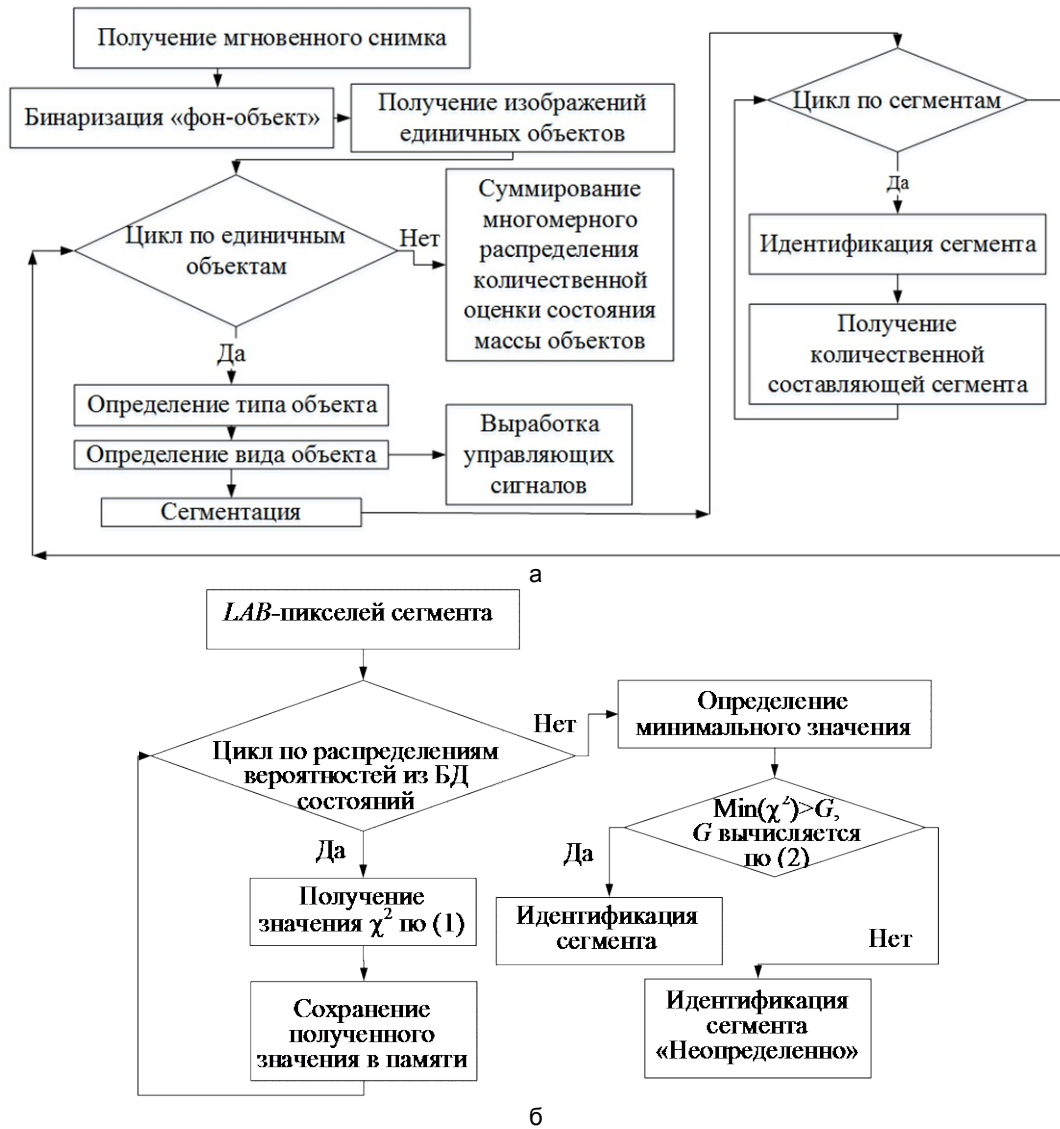


Рис. 1. Блок-схемы: алгоритма рабочего режима системы компьютерного зрения (а) и подсистемы идентификации состояния (б)

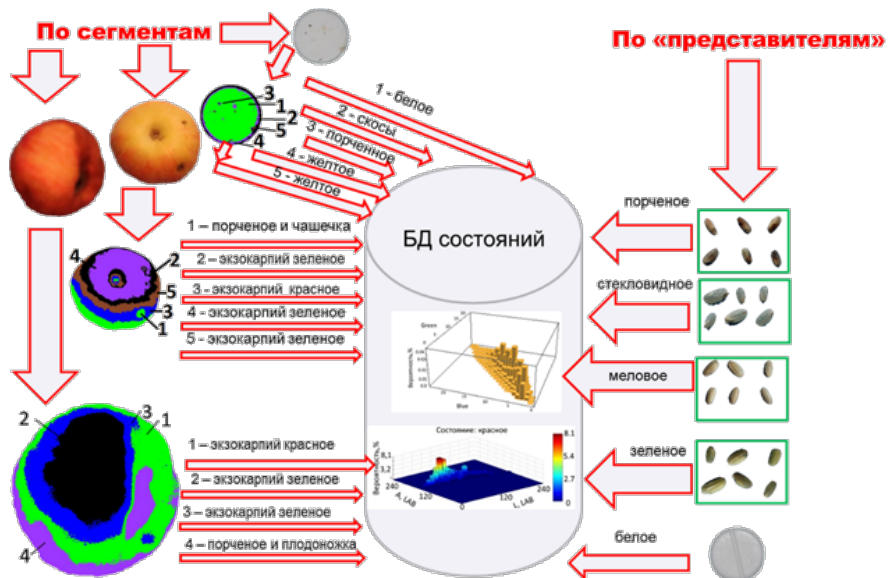


Рис. 2. Процедуры подготовки обучающей базы данных (БД) в натуральных экспериментах с зерновой массой риса, фруктовым сырьем и фармакологической продукцией

Алгоритмы подсистемы идентификации

Для запуска рабочего режима СКЗ (рис. 1) необходимы результаты предварительного обучения СКЗ после создания обучающей базы данных (БД) из реальных объектов (рис. 2). Следует учитывать сильное влияние спектра и интенсивности освещения при съемке объектов. Эти результаты для каждого из указанных экспертом возможного состояния участков поверхности единичного объекта содержат вероятностные распределения  $p_{ijk}^T$  – «теоретическую» вероятность попадания цветовых характеристик LAB-пикселей изображения данного участка в заданные диапазоны  $(L_i, A_j, B_k)$  интервалов  $[0;255]$  цветовых LAB-шкал при глубине цвета TrueColor, образуя тем самым БД состояний (рис. 2). Использовалось именно цветовое пространство LAB, оказавшееся предпочтительней, например, чем RGB, HSL. Здесь  $1 \leq i \leq I, 1 \leq j \leq J, 1 \leq k \leq K$ , где  $I, J, K$  – количество интервалов по каждой из осей цветового пространства LAB. Размер интервалов  $\frac{256}{I}, \frac{256}{J}$  и  $\frac{256}{K}$  влияет на точность и скорость работы СКЗ: уменьшение размера повышает точность, но снижает скорость. В тех ситуациях, когда состояния объекта имеют схожие цветовые характеристики, размер интервалов должен быть меньше, чем в случае, когда цветовые характеристики состояний сильно отличаются.

В рабочем режиме внутренним циклом является распознавание состояния каждого сегмента изображения каждого из единичных объектов на 2D-кадре. По цветовым характеристикам пикселей каждого сегмента строится распределение  $p_{ijk}$  – «эмпирическая» вероятность попадания в заданные диапазоны  $(L_i, A_j, B_k)$  характеристик пиксельной матрицы текущего сегмента распознаваемого изображения. Проверка гипотезы о принадлежности неизвестного сегмента как выборки к одному из распределений, содержащихся в БД состояний, производится по (1) с использованием критерия согласия  $\chi^2$  Пирсона.

$$\chi^2 = \begin{cases} \left\{ \begin{array}{l} \frac{(p_{ijk} - p_{ijk}^T)^2}{p_{ijk}^T}, p_{ijk}^T \neq 0 \\ 0, p_{ijk}^T = p_{ijk} = 0 \\ 0, p_{ijk}^T = 0 \ \& \ p_{ijk} = \frac{n_{ijk}}{N} \neq 0 \ \& \ n_{ijk} < 4 \end{array} \right. , \\ 10G, \exists p_{ijk}^T = 0 \ \& \ p_{ijk} \neq 0 \end{cases} \quad (1)$$

где  $n_{ijk}$  – количество попаданий в заданные диапазоны  $(L_i, A_j, B_k)$  характеристик пиксельной матрицы текущего сегмента распознаваемого изображения;  $N$  – число пикселей в матрице;  $G = \chi_{кр}^2$  – критическое значение критерия Пирсона. Идентификация состояния сегмента производится по минимальной из рассчитанных по (1) величин  $\chi^2$ , рис. 1, б: вычисляется  $\chi^2$  для каждого из возможных состояний текущего сегмента и выбирается минимальный  $\chi_{min}^2$ . Если эта минимальная величина  $\chi_{min}^2 > G$ , то сегмент будет идентифицироваться системой как «неопределенный» (неизвестный). В противном случае считается, что текущий сегмент находится в состоянии, имеющем  $\chi_{min}^2$ .

Критическое значение  $\chi_{кр}^2 = G = G(v, \alpha)$  для (1) устанавливается в зависимости от уровня значимости  $\alpha$  и числа степеней свободы  $v$ . Число степеней свободы рассчитывается как  $v = (I-1)(J-1)(K-1) - S$ , где  $S$  – число параметров вероятностного распределения (в случае распределения Гаусса  $S = 2$ ). По заданному уровню значимости как вероятности ошибки 1 рода рассчитывается  $G(v, \alpha)$  с использованием функции распределения Пирсона (2) (рис. 3):

$$G = \chi_{кр}^2 = \begin{cases} 2Q^{-1}(v, 0, x), \text{ при } 0 < x < 1 \\ 0, \text{ при } x \leq 0 \\ \infty, \text{ при } x \geq 1 \end{cases} \quad (2)$$

где  $x = 1 - \alpha$ ;  $Q^{-1}$  – обратная регуляризованная гамма-функция;  $v$  – число степеней свободы;  $x$  – доверительная вероятность.

Как известно, при проверках статистических гипотез могут возникать ошибки первого и второго рода. Вероятность ошибки 1 рода –  $\alpha$ ;  $\beta$  – вероятность ошибки 2 рода; при уменьшении  $\alpha$  растет  $\beta$  (и наоборот). Уровень значимости подбирается экспериментально так, чтобы  $\alpha$  и  $\beta$  были приемлемо малы.

Пример идентификации состояния сегмента показан на рис. 4: получается распределение вероятностей пикселей каждого сегмента и поэтапно сравнивается с распределениями вероятностей из БД состояний.

Эффективность предлагаемого математического обеспечения СКЗ была проверена в натурных экспериментах: с зерновой массой риса, с фруктовым сырьем яблок сорта Red Delicious и с таблетками ацетилсалициловой кислоты (рис. 5).

Результатом работы СКЗ являются гистограммы распределения вероятностей, которые позволяют определить качество массы объектов и оценить их состояние в целом, как генеральной совокупности, (рис. 5), что необходимо для принятия решений в технологических процессах. В данной работе принято

ограничение  $I=J=K$  от 10 до 52. В натурном эксперименте с зерновой массой риса и фруктовым сырьем принято  $I=J=K=26$ , а в натурном эксперименте с фармакологической продукцией  $I=J=K=52$ .




Рис. 3. Поверхность зависимости  $G$  от  $\alpha$  и  $\nu$  (от 727 до 15623, т.е.  $I=J=K$  от 10 до 26)




Рис. 4. Пример идентификации состояний сегментов в натурном эксперименте с зерновой массой риса, фруктовым сырьем и фармакологической продукцией: при обучении по «представителям» зерен риса (а); исходное изображение яблок (б); результат бинаризации изображения б (в); результат выделения единичного объекта из в (г); результат сегментации единичного объекта г и идентификации его сегментов (1, 4 – порченое, 2, 3 – зеленое) (д); изображение порченной таблетки аспирина (е); сегментация и результат распознавания сегментов изображения е (1 – белое, 2 – скосы, 3 – порченое, 4, 5 – желтое) (ж)

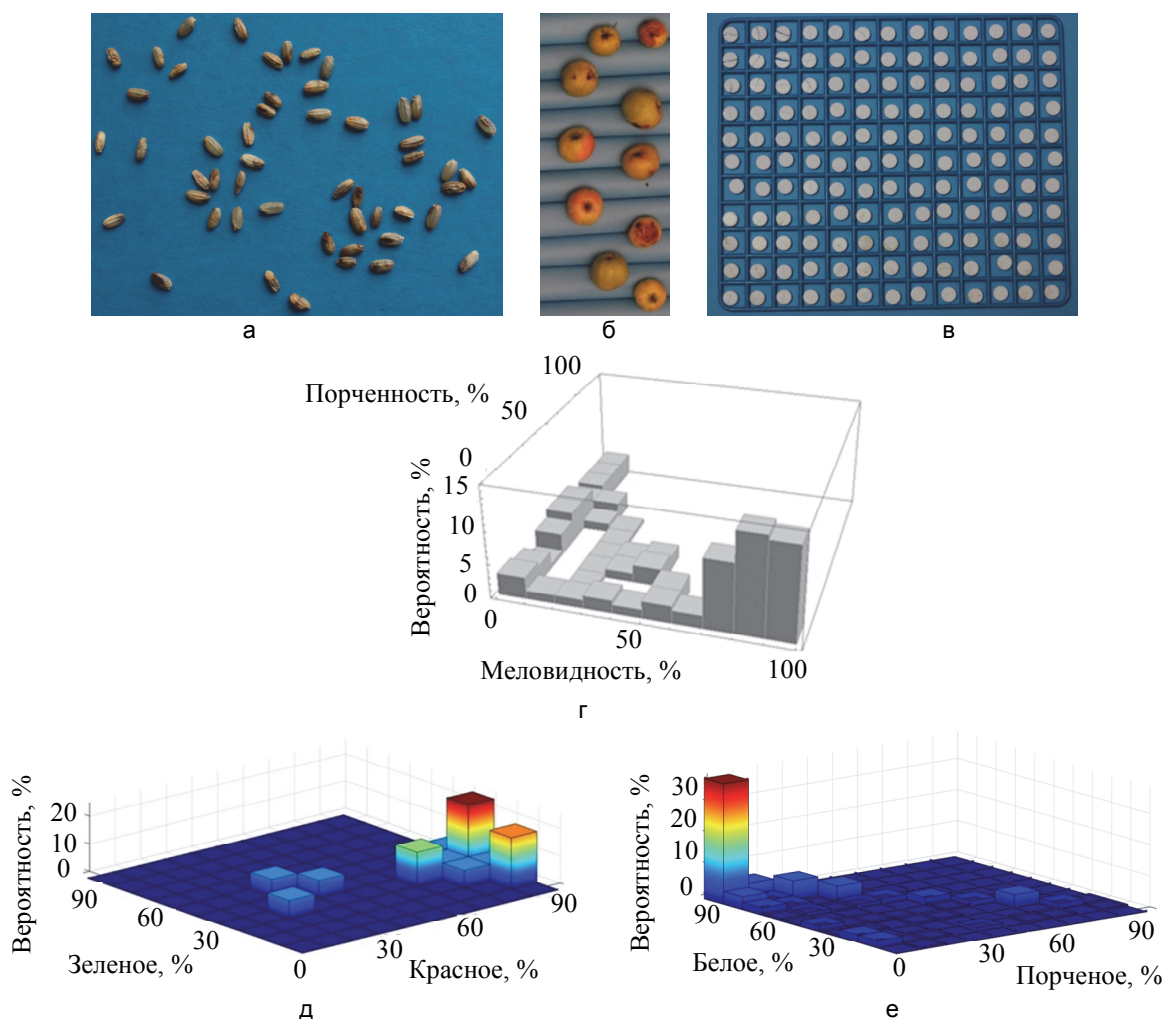


Рис. 5. Примеры изображений объектов (а, б, в) и результат оценки состояния генеральной совокупности в натуральных экспериментах (г, д, е): а, г – зерновки риса; б – яблоки сорта Red Delicious, в, д, е – таблетки ацетилсалициловой кислоты

### Точность и скорость работы подсистемы идентификации

Эксперименты проводились на компьютере со следующими характеристиками: процессор Intel i7-3930K, тактовая частота 3,2 ГГц; количество ядер 6; количество потоков 12; кэш-память 12 МБ; оперативная память DDR3 16 ГБ 1333 МГц; материнская плата MSI X79A-GD45 (8D) (MS-7760); жесткий диск SSD Kingston SNM225-S2/160GB; операционная система Windows 7; установленная платформа .NET Framework 4.5. Точность, скорость работы и сравнение с теоретическим пределом ускорения по закону Амдала–Уэра в натурном эксперименте с фруктовым сырьем оценены в [5].

Состояния объектов таблеток аспирина имеют более схожие цветовые характеристики, чем состояния яблок. По этой причине в натурном эксперименте с фруктовым сырьем принято минимально возможное  $I=J=K=26$ , дающее достаточную точность, в натурном эксперименте с фармакологической продукцией разбиение на интервалы, как в эксперименте с фруктовым сырьем, не позволяло различать близкие по цвету состояния, по этой причине было принято  $I=J=K=52$ . Увеличение числа интервалов повышает точность работы СКЗ, однако влечет за собой снижение скорости обработки изображения мгновенного видеокadra (рис. 6).

Из рис. 6 видно, что увеличение числа интервалов значительно увеличивает время работы идентификации сегментов. Так, например, при числе пикселей изображения 2293137 и  $I=J=K=10$  на работу блока распознавания требуется 0,343 с (13,27% от общего времени), при  $I=J=K=26$ : 0,874 с (29,38% от общего времени), а при  $I=J=K=52$ : 14,91 с (87,5% от общего времени).

Точность рассчитывалась как отношение количества верно идентифицированных СКЗ-состояний сегментов к их общему количеству. Выявлено, что на изображениях с инспекционного конвейера с фруктовым сырьем на данном виде объектов СКЗ точность равна 98,5%. На объектах в виде таблеток аспирина СКЗ точность равна 93,2%, а на объектах зерновой массы риса – 95,4%.

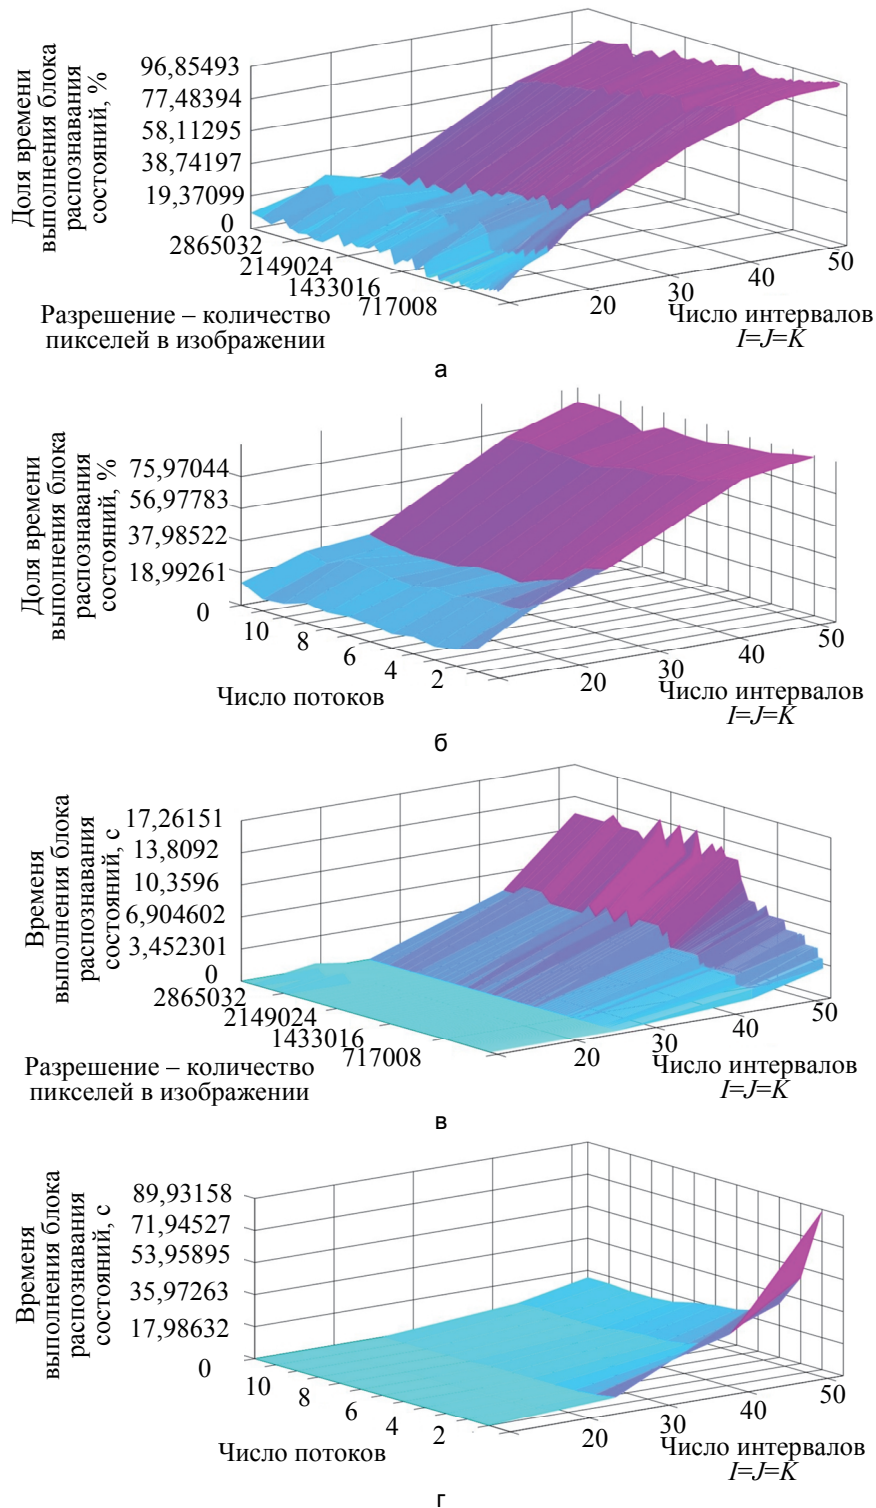


Рис. 6. Влияние числа интервалов  $I, J, K$  на обработку мгновенного видеокadra с 143 таблетками аспирина: % времени подсистемы идентификации сегментов от общего времени работы при фиксированном числе потоков 12 (а); при числе пикселей изображения 2293137 (б); время идентификации при фиксированном числе потоков 12 (в); время идентификации при числе пикселей изображения 2293137 (г)

### Заключение

Предложено математическое обеспечение подсистемы идентификации и оценки состояния участков поверхности массового количества единичных материальных объектов (как генеральной совокупности), дополняющее функциональность системы компьютерного зрения распознавания типов и видов объектов на 2D-изображении, с высокой вариабельностью внутри их типов и видов, а также близостью са-

мих видов. Алгоритмы качественной и количественной оценки состояния каждого единичного материального объекта (элемента генеральной совокупности), чувствительные к деталям их видимой поверхности, основаны на критерии Пирсона.

Показана эффективность подсистемы на изображениях с зерновой массой риса, фруктовым сыром и фармакологической продукцией.

Из известных факторов, влияющих на работу программного обеспечения (установленный тип процессора, тип и размер оперативной памяти, среда разработки программного обеспечения, оптимальность кода, использование методов параллельного программирования), выявлено влияние использования языка программирования C++ вместо C#: это позволяет увеличить скорость работы системы компьютерного зрения более чем в 3 раза. Оценена эффективность подсистемы по требованиям к быстродействию (производительность с возможностью работы в реальном масштабе времени). Показаны возможности снижения времени обработки видеокadra в рабочем режиме оптимизацией последовательных вычислений и организацией параллельных вычислений: исследовано влияние размера изображения, количества единичных объектов на изображении и числа процессоров. Ориентировочно работы разработанной системы с одним центральным компьютером достаточно, например, для инспекционного конвейера. При этом необходимо учитывать сильную зависимость скорости от числа интервалов в шкалах цветовых осей *LAB* в базе данных состояний: изменение этого числа в разы приводит к увеличению времени счета подсистемы на порядок, резко поднимая ее долю в общем времени работы системы компьютерного зрения.

Для задач фотосепарации может возникнуть необходимость разработки другой вычислительной архитектуры – системы специализированных вычислительных плат (например, платы Siemens 6ES7195-3BA10-0YA0). Это один из способов увеличения производительности системы компьютерного зрения переносом вычислений с CPU на специализированные платы. При работе на классическом компьютере данные постоянно помещаются в оперативную память, и происходит частое обращение к ней. В случае использования специализированных плат, оснащенных памятью, будет происходить более редкое обращение к оперативной памяти. В результате этого сократится время транспортировки данных по системным шинам материнской платы, на каждой плате будет обрабатываться свой блок данных, и в оперативную память будет помещаться только результат вычислений с этим блоком.

## Литература

1. Зиятдинова В.А., Шаззо А.Ю., Усатиков С.В., Погорелова И.И. Оценка качества риса с использованием современных методов анализа цветовых характеристик единичных зерен // Известия ВУЗов. Пищевая технология. 2015. № 2-3. С. 100–104.
2. Da-Wen Sun. *Computer Vision Technology for Food Quality Evaluation*. Academic Press, 2008. 600 p.
3. Бородихин А.С., Горонков К.А., Руденко О.В., Троянова Т.Л., Усатиков С.В. Блок распознавания растительного сырья экспертной системы мониторинга показателей безопасности и качества при производстве консервов // Фундаментальные исследования. 2011. №8-3. С. 607–612.
4. Остапов Д.С. Подходы к идентификации состояния 3D-поверхности по 2D-изображениям единичных объектов и их массового количества // Вестник АГТУ. Серия: Управление, вычислительная техника и информатика. 2016. № 4. С. 55–64.
5. Остапов Д.С., Усатиков С.В. Повышение эффективности программной реализации алгоритмов распознавания изображений с детальной оценкой состояния массового количества объектов // Научный журнал КубГАУ. 2016. №124. С. 611–622. doi: 10.21515/1990-4665-124-037
6. Serge T., Wolf L., Poggio T. Object recognition with features inspired by visual cortex // Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego, USA, 2005. V. 2. P. 994–1000.
7. Gujjar H.S., Siddappa M. Recognition and classification of different types of food grains and detection of foreign bodies using neural networks // International Journal of Computer Applications. 2014. P. 12–17.
8. Yao B., Khosla A., Fei-Fei L. Combining randomization and discrimination for fine-grained image categorization // Computer Vision and Pattern Recognition. 2011. P. 1577–1584. doi: 10.1109/CVPR.2011.5995368
9. Ciresan D., Meier U., Schmidhuber J. Multi-column deep neural networks for image classification // Computer Vision and Pattern Recognition. 2012. P. 3642–3649. doi: 10.1109/CVPR.2012.6248110
10. Korytkowski M., Rutkowski L., Scherer R. Fast image

## References

1. Ziyatdinova V.A., Shazzo A.Yu., Usatikov S.V., Pogorelova I.I. Rice quality assessment using modern methods of single grains color characteristics analysis. *Izvestia Vuzov. Pishhevaya Tekhnologia*, 2015, no. 2-3, pp. 100–104. (In Russian)
2. Da-Wen Sun. *Computer Vision Technology for Food Quality Evaluation*. Academic Press, 2008, 600 p.
3. Borodikhin A.S., Goronkov K.A., Rudenko O.V., Troyanova T.L., Usatikov S.V. The block of recognition of vegetative raw materials of expert system of monitoring of indicators of safety and quality by manufacture of canned food. *Fundamental Research*, 2011, no. 8, pp. 607–612. (In Russian)
4. Ostapov D.S. Approaches to the identification of the state of 3D-surface by 2D-objects images and their mass number. *Vestnik of Astrakhan State Technical University. Series: Management, Computer Science and Informatics*, 2016, no. 4, pp. 55–64. (In Russian)
5. Ostapov D.S., Usatikov S.V. Improving the efficiency of the software implementation of image recognition algorithms with a detailed assessment of the status of the massive number of objects. *Scientific Journal of KubSAU*, 2016, no. 124, pp. 611–622. (In Russian)
6. Serge T., Wolf L., Poggio T. Object recognition with features inspired by visual cortex. *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. San Diego, USA, 2005, vol. 2, pp. 994–1000.
7. Gujjar H.S., Siddappa M. Recognition and classification of different types of food grains and detection of foreign bodies using neural networks. *International Journal of Computer Applications*, 2014, pp. 12–17.
8. Yao B., Khosla A., Fei-Fei L. Combining randomization and discrimination for fine-grained image categorization. *Computer Vision and Pattern Recognition*, 2011, pp. 1577–1584. doi: 10.1109/CVPR.2011.5995368
9. Ciresan D., Meier U., Schmidhuber J. Multi-column deep neural networks for image classification. *Computer Vision and Pattern Recognition*, 2012, pp. 3642–3649. doi: 10.1109/CVPR.2012.6248110
10. Korytkowski M., Rutkowski L., Scherer R. Fast image



- classification by boosting fuzzy classifiers // *Information Sciences*. 2016. V. 327. P. 175–182. doi: 10.1016/j.ins.2015.08.030
11. Xingha Y., Weifeng L., Dapeng T., Jun C. Canonical correlation analysis networks for two-view image recognition // *Information Sciences*. 2017. V. 385–386. P. 338–352. doi: 10.1016/j.ins.2017.01.011
12. Panda P., Ankit A., Wijesinghe P., Roy K. FALCON: feature driven selective classification for energy-efficient image recognition // *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*. 2017. V. PP. N 99. P. 1–13. doi: 10.1109/tcad.2017.2681075
13. Stepinski T., Niesterowicz J., Stepinski J. Pattern-based regionalization of large geospatial datasets using complex object-based image analysis // *Procedia Computer Science*. 2015. V. 51. N 1. P. 2168–2177. doi: 10.1016/j.procs.2015.05.491
14. Romei A., Ruggeieri S. A multidisciplinary survey on discrimination analysis // *Knowledge Engineering Review*. 2014. V. 29. N 5. P. 585–638. doi: 10.1017/S0269888913000039
- classification by boosting fuzzy classifiers. *Information Sciences*, 2016, vol. 327, pp. 175–182. doi: 10.1016/j.ins.2015.08.030
11. Xingha Y., Weifeng L., Dapeng T., Jun C. Canonical correlation analysis networks for two-view image recognition. *Information Sciences*, 2017, vol. 385–386, pp. 338–352. doi: 10.1016/j.ins.2017.01.011
12. Panda P., Ankit A., Wijesinghe P., Roy K. FALCON: feature driven selective classification for energy-efficient image recognition. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 2017, vol. PP, no. 99, pp. 1–13. doi: 10.1109/tcad.2017.2681075
13. Stepinski T., Niesterowicz J., Stepinski J. Pattern-based regionalization of large geospatial datasets using complex object-based image analysis. *Procedia Computer Science*, 2015, vol. 51, no. 1, pp. 2168–2177. doi: 10.1016/j.procs.2015.05.491
14. Romei A., Ruggeieri S. A multidisciplinary survey on discrimination analysis. *Knowledge Engineering Review*, 2014, vol. 29, no. 5, pp. 585–638. doi: 10.1017/S0269888913000039

### Авторы

**Остапов Дмитрий Сергеевич** – аспирант, Кубанский государственный технологический университет, Краснодар, 350072, Российская Федерация, krasnodar93@mail.ru

**Усатилов Сергей Васильевич** – доктор физико-математических наук, доцент, профессор, Кубанский государственный университет, Краснодар, 350040, Российская Федерация, SV@Usatkov.com

### Authors

**Dmitry S. Ostapov** – postgraduate, Kuban State Technological University, Krasnodar, 350072, Russian Federation, krasnodar93@mail.ru

**Sergey V. Usatkov** – D.Sc., Associate Professor, Professor, Kuban State University, Krasnodar, 350040, Russian Federation, SV@Usatkov.com