

УДК 004.932.2

## АНАЛИЗ ЭФФЕКТИВНОСТИ ВЫДЕЛЕНИЯ ГРАНИЦ СЕГМЕНТОВ СРЕДСТВАМИ НЕЙРОННЫХ СЕТЕЙ

© А. В. Кугаевских<sup>1,2,3</sup>, А. А. Согрешилин<sup>2</sup>

<sup>1</sup>Новосибирский государственный технический университет,  
630073, г. Новосибирск, просп. К. Маркса, 20

<sup>2</sup>Новосибирский государственный университет,  
630090, г. Новосибирск, ул. Пирогова, 1

<sup>3</sup>Институт автоматизации и электрометрии СО РАН,  
630090, г. Новосибирск, просп. Академика Коптюга, 1  
E-mail: a-kugaevskikh@yandex.ru

В работе приведена архитектура нейросети выделения краёв. Проведено сравнение разных фильтров для нейронов первого слоя. Обучение нейросети с помощью алгоритма на базе косинусной меры показало существенно более худшие результаты по сравнению с алгоритмом обратного распространения ошибки. Также в работе указаны оптимальные параметры функционирования нейронов первого слоя. Предлагаемая архитектура выполняет поставленные задачи по выделению краёв.

*Ключевые слова:* выделение краёв, фильтр Габора, косинусная мера, нейронные сети, вейвлет сомбреро, гиперболический тангенс.

DOI: 10.15372/AUT20190413

**Введение.** Яркостная сегментация изображений является фундаментом для систем компьютерного зрения. На использовании результатов яркостной сегментации строятся механизмы цветового постоянства, анализа движения, распознавания через выделение локальных признаков, которыми чаще всего служат пересечения линий. Решение задачи выделения краёв основано на резком перепаде яркости на границе сегмента. Для нахождения резкого перепада традиционно используются фильтр Собеля и алгоритм Канни [1]. На изменении яркости в некоторой окрестности основаны детекторы углов, такие как детектор Харриса [2], детектор Ферстнера [3], SUSAN-детектор [4], при этом детекторы углов подвержены шуму и часто дают ложные срабатывания.

В нейросетевых моделях механизмы выделения краёв и детекции углов (например, фильтр Гаусса или фильтр Габора) используются ещё и для выявления локальных признаков. В основе таких моделей как HMAX [5], LPREEN [6] лежит фильтр Габора. На его базе построены модели нейронов простого оппонирования и двойного оппонирования [7–10]. Фильтр Гаусса как основа оппонентного процесса используется в [11]. Простое и двойное оппонирование на базе фильтра Габора или фильтра Гаусса применяется в моделировании эффекта цветового постоянства для выравнивания уровня освещённости сцены.

В задаче нейросетевой сегментации помимо свёрточных и глубоких сетей применяются классические архитектуры: pulse-coupled neural network [12], многослойный перцептрон [13], самоорганизующиеся карты Кохонена [14]. Независимо от модели нейронной сети выделение локальных признаков осуществляется через определение перепада яркости.

Фильтр Габора чаще всего используется для выделения текстур за счёт своей периодичности, при этом в задаче выделения краёв альтернативой ему выступает вейвлет «мексиканская шляпа» («сомбреро»). Для дальнейшего построения систем компьютерного зрения необходимо проанализировать применимость разных фильтров с точки зрения точности выделения краёв и обучаемости.




Рис. 1. Нейросети выделения краёв

**Архитектура нейросети выделения краёв.** Для выделения краёв на изображении предлагается использование свёрточной нейронной сети по целому ряду соображений. Во-первых, операция свёртки, равносильная взвешенной сумме, позволяет выделять линии строго определённой длины и ориентации за счёт сконфигурированного на конкретную длину и ориентацию ядра, что, в свою очередь, позволяет в дальнейшем получить локальные признаки для классификации. Во-вторых, такая нейронная сеть функционально подобна происходящему в первичной зрительной коре. Распространение свёртки с ядром фильтра Габора для выделения линий было обусловлено сходством с процессом, происходящим в первичной зрительной коре. В-третьих, архитектура свёрточной нейронной сети позволит добавлять к ней цветовую сегментацию, выделение движения, построение плана сцены и распознавание объектов с использованием данных выделения краёв.

На вход нейросети подаётся компонента  $L^*$  изображения в цветовом пространстве CIE  $L^*a^*b^*$  [15]:

$$L^* = 116f(Y/Y_n) - 16, \tag{1}$$

где  $Y$  — компонента цветового пространства CIE  $XYZ$ ;  $Y_n = 100$  —  $Y$ -координата белой точки для источника света D65 и обозревателя  $2^\circ$ ;

$$f(x) = \begin{cases} x^{1/3}, & x > (6/29)^3, \\ (29/6)^2/3 + 4/29 & \text{иначе.} \end{cases}$$

Для осуществления яркостной сегментации предлагается использование двухслойной нейронной сети (рис. 1). На первом слое выделяются линии определённой ориентации. Второй слой отвечает за выделение комбинаций линий, в том числе и углов. Отличие от обучаемых свёрточных слоёв, в частности первого слоя простых клеток в сети неокортикса, заключается в использовании заранее сконфигурированных рецептивных полей нейронов первого слоя, что повышает предсказуемость и интерпретируемость результатов работы такой нейросети.




Рис. 2. Принцип организации связей между слоями

Каждый слой содержит нейроны четырёх типов, отличающихся конфигурацией рецептивных полей. При этом связи между слоями организованы особым образом. Каждый нейрон второго слоя ( $U_{C2}$ ) соединён только с двумя нейронами первого слоя ( $U_{S1}$ ) (рис. 2). Таким образом, нейроны второго слоя позволяют выделять линии и углы (в случае фильтра Габора) и четырёхугольники (в случае гиперболического тангенса).

**Рецептивные поля нейронов.** Типы нейронов первого слоя, так называемые простые клетки даны в табл. 1. Каждый тип нейронов представлен своей ориентационной группой, состоящей из 36 нейронов. Каждый нейрон чувствителен к линии определённой ориентации с шагом отклонения  $10^\circ$  ( $\Delta\theta$ ).

Функционирование нейронов первого слоя представляет собой двумерную свёртку окна массива яркостей пикселей и соответствующего массива весов, найденных с помощью соответствующей функции.

Первые два типа нейронов реагируют на линии предпочтительной ориентации  $\theta$ . Их рецептивные поля формируются с помощью фильтра Габора [16], который был выбран по двум причинам: во-первых, его функция позволяет формировать рецептивное поле простого нейрона для выделения линий определённой ориентации, во-вторых, в отличие от вейвлета сомбреро его постоянная компонента гораздо ближе к 0, что уменьшает паразитную активацию нейронов первого слоя. Равномерная заливка рецептивного поля такого нейрона даёт близкое к нулю значение. Фильтр Габора даёт возможность выделять светлые линии на тёмном фоне и тёмные линии на светлом фоне:

$$G_{1,2} = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right). \quad (2)$$

В [17] показано, что формула (2) имеет оптимальную постоянную компоненту фильтра, что снижает появление шума в результате свёртки. Также оптимальным для фильтрации является соотношение  $\sigma/\lambda \approx 0,56$ , выведенное через пропускную способность со значением 1 октава. Для задачи выделения краёв фильтр Габора имеет следующие параметры:  $\gamma = 0,1$ ,  $\theta \in [0; 350]$ .

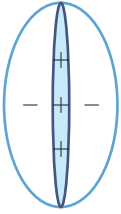
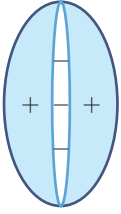
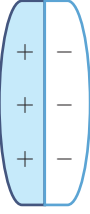
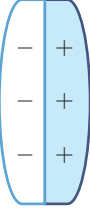
В качестве альтернативы фильтру Габора часто используют вейвлет сомбреро:

$$G = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \left(1 - \frac{x'^2 + \gamma^2 y'^2}{\sigma^2}\right). \quad (3)$$

На рис. 3 приведено сравнение графиков фильтра Габора ( $\lambda = 2$  и  $\lambda = 3$ ) и вейвлета сомбреро.

При размерах ядра  $5 \times 5$  у фильтра Габора ( $\lambda = 2$ ) наблюдается вторичный всплеск, который хорошо работает при анализе текстур, но искажает значение активации нейрона, обученного на линию конкретной ориентации. Выбор параметра  $\lambda = 3$  приводит к сдвигу

Таблица 1  
 Типы рецептивных полей нейронов первого слоя

№	Рисунок	Функция	Параметры
1		Фильтр Габора	$\gamma = 0,1,$ $\varphi = 0$
2		Фильтр Габора	$\gamma = 0,1,$ $\varphi = -\pi$
3		Гиперболический тангенс	$k = 1$
4		Гиперболический тангенс	$k = -1$

вторичного всплеска за границы ядра фильтра Габора, при этом сохраняется толщина пика в 1 пиксель. Применение фильтра Габора предпочтительнее вейвлета сомбреро ещё и вследствие удобства подбора  $\sigma$  в зависимости от размера ядра фильтра (рис. 4).

Нейроны следующих типов необходимы для определения зон перепада яркости, причём для формирования рецептивного поля также должна использоваться гладкая функция, чтобы учесть такие моменты, как размытие в условиях тумана и нахождение теней. По этой причине не может быть применён вейвлет Хаара, но возможно сконфигурировать рецептивное поле с помощью гиперболического тангенса (рис. 5):

$$G_{3,4} = \text{th}(2kx'/\lambda). \tag{4}$$

Для учёта разного размера зон перепада яркости в (4) был введён параметр  $\lambda$ . В формулах (2) и (4) используется матрица поворота

$$\begin{cases} x' = x \cos \theta + y \sin \theta, \\ y' = -x \sin \theta + y \cos \theta. \end{cases} \tag{5}$$

Нейроны первого слоя дают близкую по значению активацию для линий в пределах




Рис. 3. Сравнение графиков фильтров (1 — фильтр Габора для  $\lambda = 2$ , 2 — фильтр Габора для  $\lambda = 3$ , 3 — вейвлет сомбреро)

$\pm 20^\circ$  отклонения от предпочтительной ориентации. Это может создать проблему для точного определения ориентации признака на следующем слое.

**Обучение сети.** В качестве рабочей гипотезы для обучения нейронной сети проверилось дельта-правило с использованием косинусной меры (Cosine). Подобный алгоритм опубликован в [18–20]. Сама косинусная мера (6) служит метрикой разнесения как можно дальше векторов  $\mathbf{A} = (u_1w_1, u_2w_2)$ ,  $\mathbf{B} = (u_3w_3, u_4w_4)$ , определяющих углы на изображении, найденные с помощью второго слоя модели яркостной сегментации

$$m_{sim} = \frac{\mathbf{AB}}{\|\mathbf{A}\| \|\mathbf{B}\|}. \quad (6)$$

В результате итеративного обучения необходимо максимизировать косинусную меру. На каждой итерации пересчитываются соответствующие веса двух нейронов второго слоя при несовпадающих углах нейронов первого слоя ( $\theta_{l1}$  и  $\theta_{l2}$ ):

$$\Delta w_l = q m_{sim} u_l \cos(\theta_{l2} - \theta_{l1}),$$

где  $u_l$  — выход обучаемого нейрона второго слоя;  $q$  — скорость обучения.

**Экспериментальная проверка.** Для обучения и экспериментальной проверки поведения разных фильтров были сформированы пакеты чёрно-белых изображений. На рис. 6 представлена часть из 630 изображений для обучения нейрона выделения линий и углов.

Проведено сравнение эффективности предложенного алгоритма на основе косинусной меры и алгоритма обратного распространения ошибки (мерой служила среднеквадратичная энергия ошибки, дельта-правило применялось с использованием локального градиента, back-prop) для каждого типа фильтров (рис. 7). Показателем оценки алгоритмов обучения и конфигураций рецептивных полей является точность работы нейронов второго слоя, т. е. определение углов и линий строго определённой ориентации. К примеру, если на сеть подан угол из линий с ориентациями 0 и  $70^\circ$ , то должен активироваться нейрон второго слоя 0 –  $70^\circ$ . Таким же образом проходило обучение сети. Точность определялась как соотношение количества верно опознанных вторым слоем сочетаний линий к общему количеству таких сочетаний (630 для нейрона на базе фильтра Габора и 35 для нейрона на базе гиперболического тангенса для каждого размера рецептивного поля).

Как видно из рис. 7, предложенный алгоритм на базе косинусной меры менее эффективен по сравнению с алгоритмом обратного распространения ошибки.




Рис. 4. Карты рецептивных полей: *a* — фильтр Габора и *b* — вейвлет сомbrero

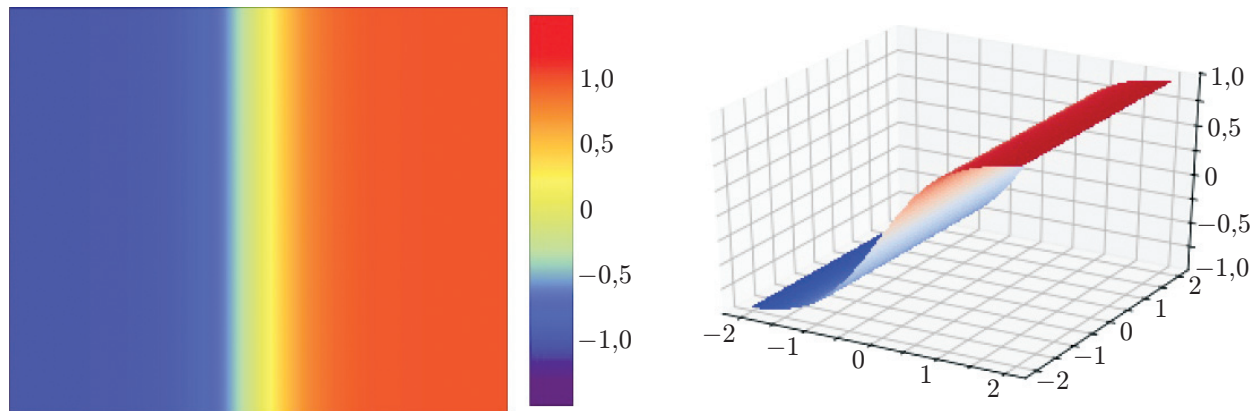


Рис. 5. Рецептивное поле по формуле гиперболического тангенса



Рис. 6. Часть изображений для обучения и тестирования нейрона выделения линий и углов

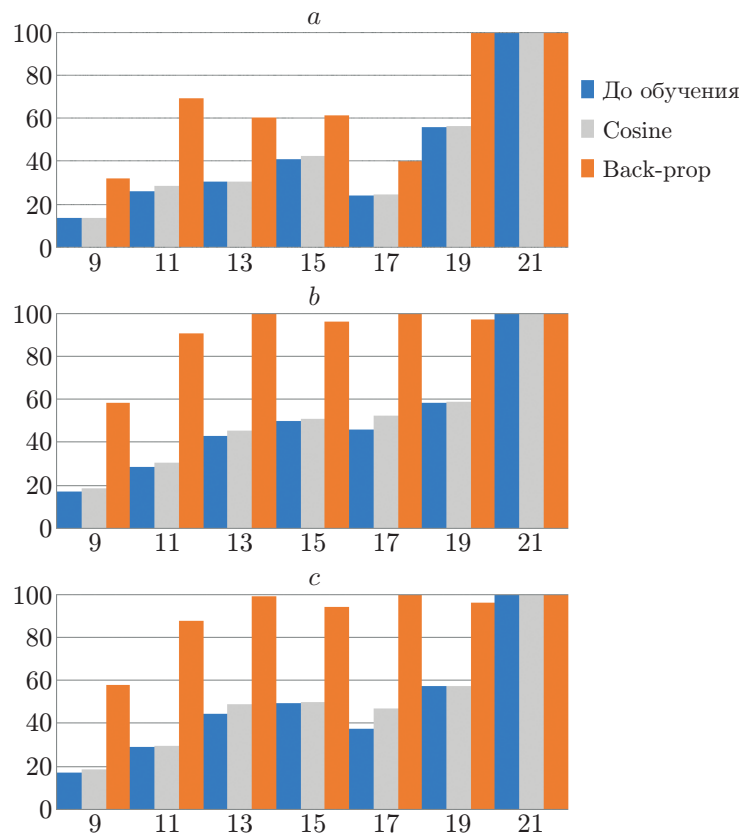


Рис. 7. Сравнение эффективности алгоритмов обучения: *a* — для фильтра Габора ( $\lambda = 2$ ), *b* — для фильтра Габора ( $\lambda = 3$ ), *c* — для вейвлета сомбреро

В табл. 2 представлены результаты эксперимента по параметру точности работы нейронов выделения линий и углов второго слоя. Исходя из этих данных видно, что оптимальным будет использование фильтра Габора ( $\lambda = 3$ ) в качестве основы нейрона выделения углов и линий, так как именно он даёт качество выделения 100 % при минимальном отклонении углов  $\Delta\theta = 10^\circ$  и размере ядра фильтра  $A_g = 13$ . Такие параметры соотносятся с некоторыми нейрофизиологическими данными об устройстве нейронов первичной зрительной коры [21].

Так как алгоритм обратного распространения ошибки показал существенно более высокий результат по сравнению с применением косинусной меры, поэтому нейроны с гиперболическим тангенсом обучались с его помощью. На рис. 8 представлены изображения для обучения и тестирования данного нейрона.

Качество выделения областей с помощью нейрона с гиперболическим тангенсом улучшается после обучения (табл. 3). При этом минимальным размером ядра является  $17 \times 17$  в отличие от нейрона выделения линий и углов.

На рис. 9 показаны результаты выделения углов и линий разной ориентации по максимальному значению активаций нейронов второго слоя. Кроме ярко выраженных границ объектов, метод выделяет незначительные перепады яркости, соответствующие мелким деталям, также отмечается высокий уровень шума, возникающий из-за паразитной активации нейронов. Этот недостаток может быть исправлен за счёт применения тормозных и обратных корректирующих связей, что является дальнейшим развитием предлагаемого подхода.

Таблица 2

Сравнение качества работы фильтров до и после обучения алгоритмом обратного распространения ошибки

$\Delta\theta$	Состояние	Размер ядра $A_g$						
		9	11	13	15	17	19	21
Фильтр Габора ( $\lambda = 2$ )								
10	До обучения	13,65	26,03	30,48	40,79	23,97	56,19	100
	После обучения	32,22	69,37	60,48	61,59	40	99,84	100
20	До обучения	32,03	50,98	43,79	57,52	43,14	59,48	100
	После обучения	69,93	91,5	95,42	96,73	67,32	100	100
30	До обучения	100	42,42	42,42	100	63,64	42,42	100
	После обучения	100	100	100	100	83,33	100	100
Фильтр Габора ( $\lambda = 3$ )								
10	До обучения	16,83	28,73	43,17	49,84	46,03	58,41	100
	После обучения	58,41	90,95	100	96,35	100	97,3	100
20	До обучения	47,06	67,32	81,7	88,89	99,35	92,81	100
	После обучения	100	100	100	100	100	100	100
30	До обучения	100	53,03	100	100	100	93,94	100
	После обучения	100	100	100	100	100	100	100
Вейвлет сомбреро								
10	До обучения	16,83	29,05	44,44	49,21	37,62	57,62	100
	После обучения	58,1	87,78	99,37	94,6	100	96,19	100
20	До обучения	47,06	64,71	72,55	82,35	99,35	77,78	100
	После обучения	100	99,35	100	100	100	100	100
30	До обучения	100	50	87,88	100	100	65,15	100
	После обучения	100	98,48	100	100	100	100	100




Рис. 8. Набор изображений для обучения нейрона с гиперболическим тангенсом



Таблица 3

Качество выделения областей (в %) до и после обучения алгоритмом обратного распространения ошибки

$\Delta\theta$	Состояние	Размер ядра $A_g$						
		9	11	13	15	17	19	21
10	До обучения	0	0	0	0	0	0	0
	После обучения	19,52	23,65	35,71	34,13	44,29	37,62	56,1
20	До обучения	0,65	0	0	0	0	0	0
	После обучения	55,56	67,97	85,62	86,93	100	100	100
30	До обучения	0	0	0	0	0	0	0
	После обучения	100	100	100	100	100	100	100



Рис. 9. Применение нейросети выделения краёв для изображения: с малым (*a*) и большим (*b*) перепадами насыщенности

**Заключение.** Экспериментальная проверка показала, что в основу нейросети выделения краёв лучше положить фильтр Габора ( $\lambda = 3$ ,  $\Delta\theta = 10^\circ$ ,  $A_g = 13$ ) на первый слой для выделения линий. При этом необходимо обучение, чтобы добиться максимальной точности выделения краёв. Для определения перепада яркости по региону применим гиперболический тангенс с параметрами  $\Delta\theta = 20^\circ$ ,  $A_g = 17$ .

Рабочая гипотеза в виде обучения нейросети на базе косинусной меры может быть признана несостоятельной. Использование алгоритма обратного распространения ошибки компенсирует ложную активацию нейронов первого слоя и приводит к существенному улучшению качества работы нейронов второго слоя.

**Финансирование.** Работа выполнена при поддержке Российского фонда фундаментальных исследований (проект № 18-37-00029).

### СПИСОК ЛИТЕРАТУРЫ

1. **Canny J.** A computational approach to edge detection // IEEE Trans. Pattern Anal. Mach. Intell. 1986. **PAMI-8**, N 6. P. 679–698.
2. **Harris C., Stephens M.** A combined corner and edge detector // Proc. of the 4th Alvey Vision Conf. Manchester, UK, 31 Aug.– 2 Sept., 1988. P. 147–151. DOI: 10.5244/C.2.23.
3. **Förstner W., Gülch E.** A fast operator for detection and precise location of distinct points, corners and centres of circular features // Proc. of the ISPRS Intercommission Conf. on Fast Processing of Photogrammetric Data. Interlaken, Switzerland, 2 June, 1987. P. 281–305.
4. **Smith S. M., Brady M.** SUSAN — a new approach to low level image processing // Intern. Journ. Comput. Vis. 1997. **23**, N 1. P. 45–78.
5. **Serre T., Wolf L., Bileschi S. et al.** Robust object recognition with cortex-like mechanisms // IEEE Trans. Pattern Anal. Mach. Intell. 2007. **29**, N 3. P. 411–426.
6. **Díaz-Pernas F. J., Martínez-Zarzuola M., Antón-Rodríguez M., González-Ortega D.** Learning and surface boundary feedbacks for colour natural scene perception // Appl. Soft Comput. 2017. **61**. P. 30–41.
7. **Graham N., Wolfson S. S.** Is there opponent-orientation coding in the second-order channels of pattern vision? // Vis. Res. 2004. **44**, Is. 27. P. 3145–3175.
8. **Loffler G.** Perception of contours and shapes: Low and intermediate stage mechanisms // Vis. Res. 2008. **48**, Is. 20. P. 2106–2127.
9. **Teichmann M., Wiltschut J., Hamker F.** Learning invariance from natural images inspired by observations in the primary visual cortex // Neural Comput. 2012. **24**, N 5. P. 1271–1296.
10. **Wang F.-P., Zhang W.-C., Zhou Z.-F., Zhu L.** Corner detection using Gabor filters // IET Image Process. 2014. **8**, Is. 11. P. 639–646.
11. **Wang Q., Spratling M. W.** Contour detection in colour images using a neurophysiologically inspired model // Cognitive Comput. 2016. **8**, N 6. P. 1027–1035.
12. **Skourikhine A. N., Prasad L., Schlei B. R.** Neural network for image segmentation // Proc. SPIE. 2000. **4120**. P. 28–35.
13. **Franklin S. W.** Retinal vessel segmentation employing ANN technique by Gabor and moment invariants-based features // Appl. Soft Comput. 2014. **22**. P. 94–100.
14. **Gemignani G., Rozza A.** A robust approach for the background subtraction based on multi-layered self-organizing maps // IEEE Trans. Image Process. 2016. **25**, N 11. P. 5239–5251.
15. **ISO 11664-4:2008.** Colorimetry. P. 4: CTE 1976  $L^*a^*b^*$  colour space. 2008–11–01.
16. **Kruizinga P., Petkov N.** Nonlinear operator for oriented texture // IEEE Trans. Image Process. 1999. **8**, N 10. P. 1395–1407.

17. **Кугаевских А. В.** Сравнение параметров фильтра Габора для эффективного извлечения краёв // Информационные технологии. 2017. **23**, вып. 8. С. 598–605.
18. **Nguyen H. V., Bai L.** Cosine similarity metric learning for face verification // Computer Vision /Eds. R. Kimmel, R. Klette, A. Sugimoto. Berlin – Heidelberg: Springer, 2011. Vol. 6493. P. 709–720.
19. **Wu X., Shi Z.-G., Liu L.** Quasi cosine similarity metric learning // Computer Vision. /Eds. C. V. Jawahar, S. Shan. Cham: Springer International Publishing, 2015. Vol. 9010. P. 194–205.
20. **Xia P., Zhang L., Li F.** Learning similarity with cosine similarity ensemble // Inform. Sci. 2015. **307**. P. 39–52.
21. **Akbarinia A., Parraga C. A.** Feedback and surround modulated boundary detection // Intern. Journ. Comput. Vis. 2018. **126**, N 12. P. 1367–1380.

*Поступила в редакцию 02.04.2019*

*После доработки 23.05.2019*

*Принята к публикации 27.05.2019*

---