

О.В. Годыч, К.Н. Гуцин, Ю.В. Никольский, В.В Пасичник, Ю.Н. Щербина

## Динамическая сегментация изображений для учебного симулятора языка жестов

Рассмотрена проблема сегментации изображений для улучшения распознавания руки в видеоряде. Приведены результаты полученных в контексте исследований, цель которых – построение компьютерного тренажера украинского языка жестов. Такой тренажер разрабатывается для людей, желающих овладеть языком жестов самостоятельно, без помощи учителя.

A problem of the image segmentation for the improvement of hand recognition in a video sequence is considered. The results obtained in the context of the researches are given. Their objective is to build a training simulator for Ukrainian Sign Language. Such simulator is worked out for the people having a wish to master the sign language by themselves, without the help of a teacher.

Розглянуто проблему сегментації зображень для покращення розпізнавання руки у відеоряді. Наведені результати отримано в контексті дослідження, мета якого – побудова комп'ютерного тренажера української мови жестів. Тренажер розробляється для людей, які хочуть оволодіти мовою жестів самостійно, без допомоги вчителя.

**Введение.** Авторы статьи ведут исследование по созданию адаптивного компьютерного тренажера языков жестов. Значительная часть основных идей и предложенных технологий уже обсуждались в ряде работ [1, 2], а также демонстрировались на *CeBIT* 2006, 2007 и 2008. Главная цель проекта – разработка доступного решения для людей, желающих самостоятельно овладеть языком жестов, основой которого являются алгоритмы распознавания дактилей – конфигураций пальцев рук, соответствующих жестам, определенным для конкретного языка жестов [1].

К сожалению, предложенные алгоритмы имеют высокую результативность лишь на изображениях (кадрах видеоряда) с однородным фоном. Для избавления от этого ограничения предложено разработать решение для отсеивания фона, т.е. алгоритм сегментации изображений, основанный на теории самоорганизационных карт Кохонена (*SOM – Self-Organizing Maps*).

Один из подходов к сегментации изображений состоит в трактовке этого процесса как задачи кластеризации, где объектами группирования являются пиксели изображения, а кластерами – сегменты. Итак, будем пользоваться термином *кластеризация изображения* тогда, когда будем говорить о способе получения ин-

формации относительно содержания изображения. Самоорганизационные карты Кохонена и их вариации являлись темой наших исследований в течение нескольких лет [3], [4], а потому использование *SOM* стало естественным выбором для реализации кластеризации изображений. Значительная часть проведенного исследования посвящена анализу цветных пространств и построению структур данных из кадров видеоряда для наиболее полного использования свойства *SOM*, заключающегося в сохранении топологии в течение сегментации изображений. Сегментация изображений – важная проблема и распространенная тема исследований. Далее приведен краткий обзор исследований по использованию *SOM* с целью кластеризации изображений, проведенных авторами работ, а также кратко их результат или недостаток.

- Предложен двухэтапный процесс на основе *SOM* с одномерной решеткой, где нейросеть *SOM* на первом этапе учится, на втором – она кластеризуется, используя *K-means* алгоритм для определения сегментов на изображении. Основным недостатком такого подхода – использование неполной информации о цвете: лишь оттенок (*hue*) и насыщенность (*saturation*) использовались для построения данных, примененных в обучении [5].

- Предложена уникальная схема подготовки данных с использованием не только цвета, но и информации о текстуре, что позволяет повысить результативность сегментации с 53,6 (без использования текстур) до 61,3%. Приведенные тесты основывались на изображениях высокой сложности [6] и [7].

- Предложен алгоритм на основе *SOM* для распознавания кожи. Соответственно приведенным результатам, эффективность распознавания составила 94% в сравнении со стандартными подходами [8].

- Разработан многоэтапный алгоритм кластеризации для сегментации цветных изображений. На первом этапе применяют *SOM* для упрощения данных, что дает возможность использовать подходы, являющиеся эффективными, но медленными на сложных и объемных данных [9].

- Использована не только цветная (довольно часто для представления пикселей изображения используют трехмерное цветовое пространство *RGB*), но и пространственная информация о положении пикселей изображения. При этом для обучения *SOM* уже использовались пятимерные векторы  $(X, Y, R, G, B)$ . Дополнительно был введен алгоритм объединения кластерных блоков в наперед определенное количество по определенным семантическим признакам [10].

- Исследование сосредоточено на использовании одноизмеримой *SOM*. Наилучшие результаты сегментации были получены в конфигурации, где первый и последний нейрон соединены, образуя нейронное кольцо [11].

- Обсуждается использование адаптивного алгоритма сегментации на основе *SOM* [12], где как и в [11] используется одномерная решетка. Главное отличие предложенного в этой работе алгоритма состоит в реализации адаптивной стратегии расщепления и объединения с целью автоматического поиска наиболее адекватного количества кластеров. Дополнительно, для дальнейшего улучшения результатов сегментации в условиях изменения освещения

и фона, разработан алгоритм реагирования на динамическое изменение цветов в пространстве *HSI* (*Hue, Saturation, Intensity*) с использованием комбинации самоорганизационных и контролируемых процессов обучения. Результаты тестов подтверждают высокую эффективность разработанных алгоритмов. Заметим, что большинство тестовых изображений были малого размера, автоматически упрощающих задачу, и имели фон, близкий к однородному.

### **Динамическая сегментация изображений**

Обсуждение теоретических и алгоритмических основ осуществленного исследования разделено на две части, одна из которых освещает этап подготовки данных для преобразования графической информации из видеоряда в векторное пространство, пригодное для использования *SOM* (обучение и интерпретация). Эффективность подготовки данных непосредственно влияет на качество кластеризации изображений. Для упрощения объяснения даны в контексте одного кадра (изображения), что не влияет на их применимость ко всем кадрам видеоряда.

### **Подготовка данных**

Начальный этап подготовки данных состоит в выборе векторного пространства для представления каждого пикселя изображения. Процесс обучения *SOM* – одна из наиболее требовательных к вычислительным ресурсам частей предложенного подхода. Учитывая требование выполнения кластеризации изображения в реальном времени, последующий этап подготовки данных – уменьшение объема данных, используемых для обучения *SOM*.

Известно, что способ работы *SOM* согласуется с принципами работы мозга. Одно из главных свойств *SOM* – сохранение топологии входного пространства в течение учебного процесса. Новейшие исследования человеческого мозга свидетельствуют, что сигналы-реакции кортекс поступают в том же топологическом порядке, что и органы чувств (глаза), передающие информацию о цвете [13]. С учетом этого *SOM* – одна из технологий, естествен-

ным образом пригодных для обработки визуальной информации.

Цвет представляет собой реакцию мозга на конкретные визуальные раздражители. Поэтому, чтобы научить *SOM* отображать топологию изображения (в смысле взаимного расположения пикселей по отношению к их информации о цвете) тем же способом, как это воспринимает человеческий глаз, необходимо выбрать цветное пространство для описания пикселей, наиболее точно моделирующее способ получения сенсорами глаза визуальной информации. Глаз получает информацию о цвете по трем каналам, отвечающим красному, зеленому и синему цвету [14]. Полученные световые сигналы объединяются мозгом, порождая разные ощущения цвета, обозначенные организацией *CIE* (*Commission Internationale de l'Eclairage* (French)) [15] так: яркость (*Brightness*), оттенок (*Hue*) и цветность (*Colourfulness*). Комиссия *CIE* определила систему, классифицирующую цвета в соответствии с человеческой системой восприятия визуальной информации. Эта система представляет собой основу трихроматической теории, описывающей способ, в котором красный, зеленый и синий цвета могут создать произвольный видимый цвет так же, как человеческий глаз использует три сенсора цвета. Цветное пространство определяет, как цвет должен быть специфицирован, создан и визуализирован. Существует несколько цветовых пространств, использование которых зависит от особенностей сферы применения. Некоторые цветовые пространства линейные с точки зрения восприятия информации, что означает: изменение на  $n$  единиц произвольной компоненты цвета приводит к такому же ощущению величины изменения независимо от того, в каком месте пространства оно состоялось [14]. Свойство линейного восприятия дает возможность цветовым пространствам лучше моделировать систему зрения человека. Как оказалось, большинство цветовых пространств, используемых в современных форматах изображений, не владеют свойством линейности восприятия. Например, *BMP* и *PNG* использу-

ют пространство  $RGB^1$ , *JPEG* использует  $YCbCr$ , который является преобразованием пространства  $RGB$ ,  $HSL^2$  – еще одно широко используемое пространство, базирующееся на  $RGB$ . Вместе с тем цветовые пространства на основе *CIE*, такие как *CIE<sub>Luv</sub>* и *CIE<sub>Lab</sub>* – почти линейные [14] и наиболее пригодны для использования в *SOM*, что было подтверждено экспериментально. Пространство *CIE XYZ* представляет собой абсолютное пространство (приборонезависимое), где каждый видимый цвет имеет неотъемлемые координаты  $X$ ,  $Y$  и  $Z$  [16]. Пространство *CIE<sub>Lab</sub>* получают из *CIE XYZ* нелинейным преобразованием  $XYZ$  в  $L^*, a^*, b^*$  [17].

Первичные входные данные (кадры из видеоряда), использованные в исследовании, применяли несжатый 24-битный формат *BMP* (8 бит на каждый канал), базирующийся на пространстве  $RGB$ . Для конвертирования векторов  $(r, g, b) \in RGB$  в  $(L^*, a^*, b^*) \in CIE_{Lab}$  необходимо применить промежуточные преобразования с использованием пространства *CIE XYZ* [17]. Превращая каждый пиксел оригинального изображения в пространстве  $RGB$ , формируем изображение в пространстве *CIE<sub>Lab</sub>*, которое и используем для дальнейшей обработки. Заметим, что при использовании *SOM* часто употребляют евклидово расстояние для вычисления отличия между элементами входного пространства<sup>3</sup>, необходимого для поиска нейронов наилучшего приближения [13]. Вместе с тем именно евклидово расстояние используют в просторные *CIE<sub>Lab</sub>* для вычисления отличия между элементами пространства, которыми являются пиксели изображения [16]. Забегая вперед, рассмотрим рис. 1, иллюстрирующий важность выбора цветового простран-

<sup>1</sup> *BMP*-файлы без компрессии и многие другие файловые форматы используют 1, 4, 8, 16, 24 или 32 бита для сохранения пикселей изображения.

<sup>2</sup> Имеет альтернативные названия *HSI*, *HSV*, *HCI*, *HVC*, *TSD* и т.д. [14].

<sup>3</sup> Выбор способа вычисления расстояния между элементами входного пространства обусловлен свойствами этого пространства, и использование евклидова расстояния не обязательно.

ства для предложенного подхода, где видно, что именно использование пространства *CIE-Lab* обеспечивает наилучший из приведенных результатов кластеризации изображения.

Для уменьшения объема данных, используемых для обучения *SOM*, предложено разделить изображение на сегменты размером  $n \times n$  пикселей. Для каждого образованного сегмента ищем два наиболее отдаленных пикселя, которые и будут формировать учебное множество. Поиск наиболее отдаленных пикселей в сегментах должен использовать формулу расстояния, соответствующего выбранному цветовому пространству. Далее приведен пример изображения  $A$  размером  $4 \times 4$  пикселя, представленного в пространств *CIE-Lab* и разделенного на четыре сегмента  $2 \times 2$  пикселя каждый.

$$A = \begin{pmatrix} (L_1^1, a_1^1, b_1^1)^T & (L_2^1, a_2^1, b_2^1)^T & (L_3^1, a_3^1, b_3^1)^T & (L_4^1, a_4^1, b_4^1)^T \\ (L_1^2, a_1^2, b_1^2)^T & (L_2^2, a_2^2, b_2^2)^T & (L_3^2, a_3^2, b_3^2)^T & (L_4^2, a_4^2, b_4^2)^T \\ (L_1^3, a_1^3, b_1^3)^T & (L_2^3, a_2^3, b_2^3)^T & (L_3^3, a_3^3, b_3^3)^T & (L_4^3, a_4^3, b_4^3)^T \\ (L_1^4, a_1^4, b_1^4)^T & (L_2^4, a_2^4, b_2^4)^T & (L_3^4, a_3^4, b_3^4)^T & (L_4^4, a_4^4, b_4^4)^T \end{pmatrix}$$

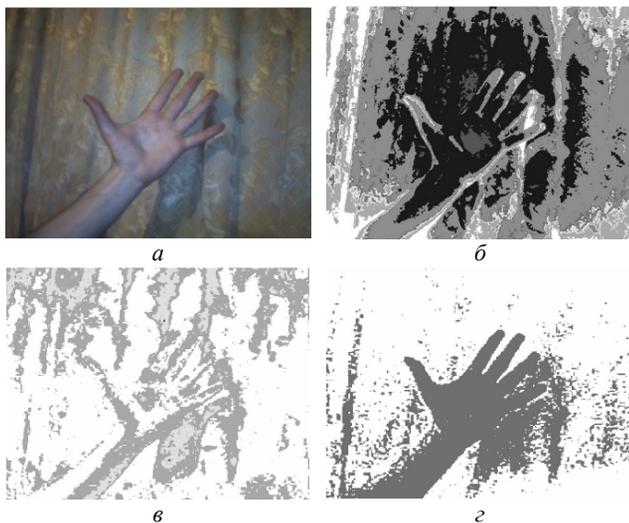


Рис. 1. Примеры кластеризации изображения, предложенным методом с использованием разных цветовых пространств:  $a$  – оригинал;  $b$  – RGB;  $c$  – HSL;  $d$  – CIE-Lab

Алгоритм 1 реализует рассмотренный подход. Отметим, что чрезмерное сокращение данных может привести к удалению важных пикселей, и как результат – к неуспешному обучению и кластеризации. На данном этапе исследования еще не сформулированы правила для

определения оптимального размера сегментов. Для получения рассмотренных в статье результатов параметры сегментации были найдены эмпирически. Вместе с тем даже применение разбишки на сегменты  $2 \times 2$  пикселя к изображению размером  $800 \times 600$  пикселей уменьшило учебное множество с 460000 до 240000 элементов. Уменьшение учебного множества, в частности, дает возможность использовать нейронную решетку меньших размеров, что автоматически существенно уменьшает время, необходимое для обучения *SOM*.

Пусть  $n$  – размер сегмента для разделения изображения,  $T$  – учебное множество, формируемое в процессе работы алгоритма. Обозначим  $j$ -и пиксел в сегменте  $S_i$  как  $S_i(j)$ . Далее в тексте оба термина *пиксел* и *вектор* употребляются в одном смысле.

**Алгоритм 1: Формирование учебного множества**

*Инициализация.* Разделим изображение на сегменты размером  $n \times n$  пикселей;  $N > 0$  – количество полученных сегментов;  $T \leftarrow \emptyset$ ;  $i \leftarrow 1$ .

1. Находим два наиболее отдаленных пикселя  $p' \in S_i$  и  $p'' \in S_i$ , используя евклидово расстояние:

a)  $\max \leftarrow -\infty, j \leftarrow 1$

b)  $k \leftarrow j + 1$

c) вычисляем расстояние между пикселями  $S_i(j)$  и  $S_i(k)$ :  $\text{dist} \leftarrow \|S_i(j) - S_i(k)\|$

d) если  $\text{dist} > \max$ , то  $p' \leftarrow S_i(j)$

$p'' \leftarrow S_i(k)$  и  $\max \leftarrow \text{dist}$

e) если  $k < n \times n$ , то  $k \leftarrow k + 1$ , и возвращаемся к шагу c)

f) если  $j < n \times n - 1$ , то  $j \leftarrow j + 1$ , и возвращаемся к шагу b)

2. Добавляем  $p' \in S_i$  и  $p'' \in S_i$  к учебному множеству:  $T \leftarrow T \cup \{p', p''\}$

3. Осуществляем переход к следующему сегменту  $i \leftarrow i + 1$ . Если  $i \leq N$ , то переходим к шагу 1, иначе – остановка.

## Интерпретация кластеров

Для организации учебного процесса *SOM* были использованы рекомендации из работ [13] и [4]. В проведенных экспериментах выбор двумерной решетки с сотовидной формой соседства между нейронами обеспечил лучшую результативность сравнительно с альтернативными структурами (одномерная решетка, прямоугольное соседство и т.д.). Более детально с выбором параметров обучения *SOM* можно ознакомиться в работе [4]. Обучение сконструированной *SOM* проводилось на учебном множестве  $T$ , сформированном с использованием алгоритма 1. Обученная *SOM* использована для организации процесса сегментации.

Свойство сохранения топологии, обученной нейросетью *SOM*, фундаментально для предложенного подхода кластеризации изображения, базирующегося на таких принципах:

- Пикселы изображения, которые распознаются топологично близкими нейронами (в смысле взаимного расположения нейронов в решетке), должны принадлежать одному и тому же кластеру.

- Происхождение меток для обозначения нейронов, принадлежащих к одному кластеру, не существенно, если алгоритм присвоения меток обеспечивает их уникальность для каждого кластера.

Эти два принципа указывают на то, что позиции нейронов в решетке, а не значения их весовых векторов, могут быть использованы для присваивания меток. При этом весовые векторы сыграют роль собственно указателей из двумерного пространства нейронов в трехмерное цветовое пространство, а позиции нейронов отвечают распределению цветов на изображении.

В результате эмпирического исследования были получены формулы для вычисления значений меток в форме оттенков серого цвета в пространстве *RGB*:  $R_j \leftarrow x_j + y_j \times \lambda$ ,  $G_j \leftarrow x_j + y_j \times \lambda$ ,  $B_j \leftarrow x_j + y_j \times \lambda$ . Значения  $x_j$  и  $y_j$  – координаты нейронов  $j = \overline{1, M}$  в решетке, где  $M$  – общее количество нейронов в *SOM*. Кон-

станта  $\lambda$  должна быть большей или равной диагонали решетки для обеспечения уникальности метки каждого нейрона.

Учитывая уникальность меток каждого нейрона возникает потребность в методе объединения нейронов на основе присвоенных меток у группы, отвечающим сегментам на изображении. На данном этапе исследования предложено несколько подходов для автоматического определения нейронов *SOM*, принадлежащих одному кластеру [18]. Представленные в этой статье результаты получены разбивками нейронов на две группы путем наложения порогового значения на присвоенные нейронам метки. Алгоритм 2 описывает этот подход.

### Алгоритм 2: Кластеризация изображения

1. *Инициализация*.  $p_j = (R_j, G_j, B_j)$  – пиксел  $j$ ;  $j = \overline{1, K}$ ;  $K > 0$  – общее количество пикселов на изображении, пронумерованных в определенном порядке;  $j \leftarrow 1$ ;  $i^*(p_j) = (R_{i^*}, G_{i^*}, B_{i^*})$  – весовой вектор нейрона наилучшего приближения *BMU* (*Best Matching Unit*) для входного вектора  $p_j$ ;  $(x_{i^*}, y_{i^*})$  – координаты нейрона  $i^*$ ; устанавливаем соответствующее значение константы  $\lambda$ .

2. Находим *BMU* для вектора  $p_j$  в обученной *SOM*, используя ту же формулу расстояния, что и при обучении (евклидова расстояния для пространства *CIELab*).

3. Вычисляем значение маркера для пиксела  $p_j$ :  $R_j \leftarrow x_{i^*} + y_{i^*} \times \lambda$ ,  $G_j \leftarrow R_j$ ,  $B_j \leftarrow R_j$ .

4. Переходим к следующему пикселу:  $j \leftarrow j + 1$ .

5. Если  $j \leq K$ , то переходим к шагу 1, иначе – останов.

### Результаты экспериментов

В этом разделе продемонстрированы результаты применения предложенного подхода к кластеризации изображений на примере задачи выделения сегмента, соответствующего

изображению руки на кадрах видеоряда. Особенность данной задачи в том, что обучение *SOM* и определение порогового значения происходило лишь на первом кадре видеоряда с применением к следующим кадрам без всяких изменений. Такой подход дает возможность осуществлять кластеризацию видеоряда в режиме реального времени.

На рис. 2 показан ряд оригинальных и кластеризованных изображений, соответствующих кадрам видеоролика ладони, которая сжимается в кулак и расправляется. Видео было записано обычной веб-камерой с возможностью записи 30 кадров в секунду и размером кадров  $800 \times 600$  пикселей. Сложность данного видео для задачи кластеризации заключается в неоднородности фона. Изображения на рис. 2 со-

ответствуют кадрам с 25-го по 60-й с шагом 5 и 10.

Главный аспект рассмотренных результатов заключается в том, что использование предложенного подхода кластеризации требует обучения *SOM* лишь на одном кадре видеоряда. Визуально легко убедиться, что все кадры были успешно кластеризованы с четким выделением пикселей, принадлежащих изображению руки, от неоднородного фона в отдельный кластер, хотя некоторые незначительные элементы фона были распознаны как часть того же кластера.

**Заключение.** Разработка предложенного подхода к сегментации изображений в нашем случае заключается в упрощении задачи распознавания дактилей. Полученные результаты экспериментов свидетельствуют о том, что данный подход применим не только для выделения изображения руки, но и других объектов.

Основной недостаток на данном этапе исследования – отсутствие полностью автоматизированной процедуры определения порогового значения для группирования нейронов. Заметим, что ведется активная работа в этом направлении. В частности, в работе [18] обсуждается подход возможности автоматического образования кластеров из нейронов обученной *SOM*.

Одно из важных направлений дальнейших исследований – повышение качества сегментации с использованием иерархической кластеризации, основная идея которой состоит в обучении *SOM* на вариациях изображения с разным уровнем детализации (начиная с наименее детальной версии).

1. Давидов М.В., Никольский Ю.В. Автоматична ідентифікація елементів жестової мови за методом еталону // Вісн. Нац. ун-ту «Львівська політехніка». Сер. Інформаційні системи та мережі. – 2007. – № 589. – С. 174–198.

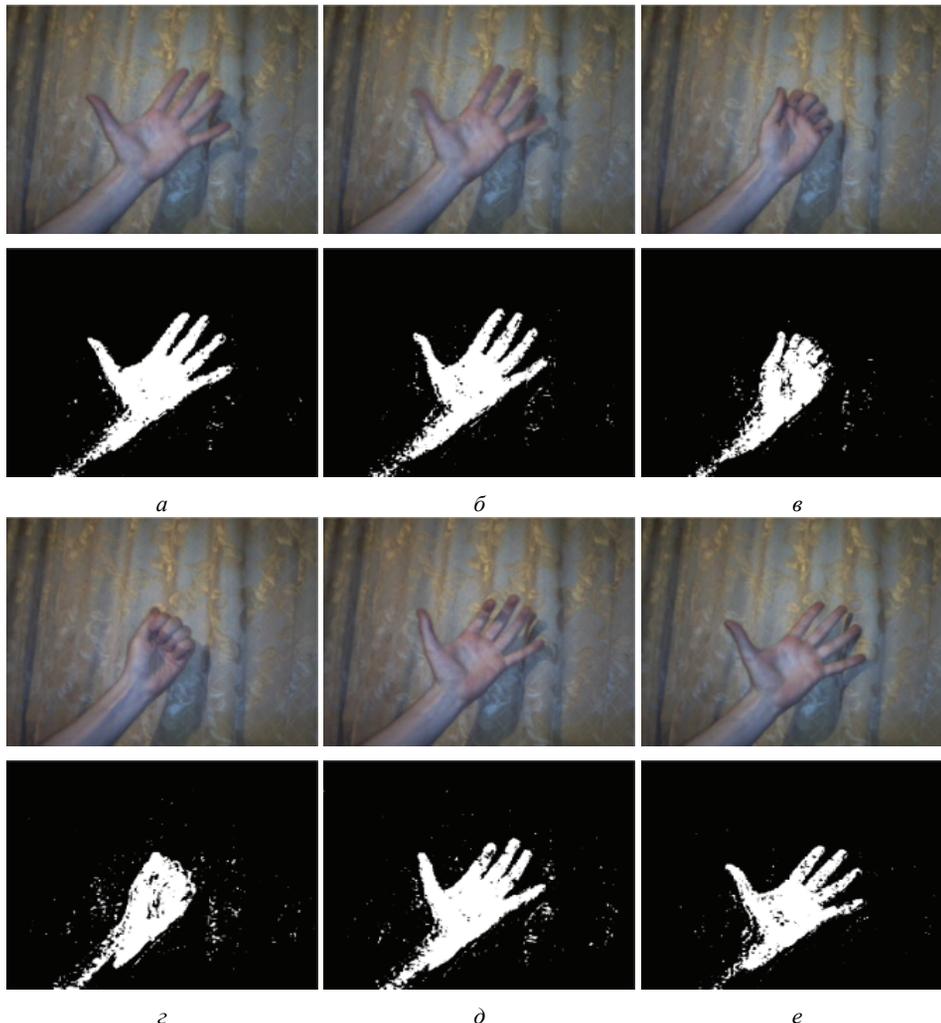


Рис. 2. Оригинальные и сегментированные видеокadres: а – 25; б – 30; в – 35; г – 40; д – 50; е – 60

2. Давидов М.В., Никольський Ю.В., Пасічник В.В. Вибір ефективного методу опрацювання зображень на основі еталону для ідентифікації елементів жестової мови // Вісн. Харківського нац. ун-ту радіоелектроніки. Сер. «АСУ і прилади автоматики». – 2008. – № 139. – С. 59–68.
3. Годич О.В., Никольський Ю.В., Щербина Ю.М. Застосування штучної нейронної мережі типу SOM для розв'язування задачі діагностування // Вісн. Нац. ун-ту «Львівська політехніка». – 2002. – № 464. – С. 31–43.
4. Дослідження ефективності алгоритмів навчання мереж Кохонена / В.В.Пасічник, О.В.Годич, Ю.В.Никольський та ін. // УСИМ. – 2006. – № 2. – С. 63–80.
5. Jander Moreira, Luciano Da Fontoura Costa Neural-based color image segmentation and classification using self-organizing maps, 1996. – <http://mirror.impa.br/sibgrapi96/trabs/pdf/a19.pdf>
6. Campbell N.W., Thomas B.T., Troscianko T. Neural Networks for the Segmentation of Outdoor Images, International Conference on Engineering Applications of Neural Networks. – 1996. – P. 343–346.
7. Campbell N.W., Thomas B.T., Troscianko T. Segmentation of Natural Images Using Self-Organising Feature Maps, University of Bristol, 1996. – P. 223–232.
8. Brown D., Craw I., Lewthwaite J. A SOM Based Approach to Skin Detection with Application in Real Time Systems, University of Aberdeen, 2001. – [http://www.bmva.ac.uk/bmvc/2001/papers/33/accepted\\_33.pdf](http://www.bmva.ac.uk/bmvc/2001/papers/33/accepted_33.pdf)
9. Akgul C.B. Cascaded self-organizing networks for color image segmentation, 2004. – [http://www.tsi.enst.fr/~akgul/oldprojects/CascadedSOM\\_cba.pdf](http://www.tsi.enst.fr/~akgul/oldprojects/CascadedSOM_cba.pdf)
10. Jiang Y., Chen K.-J., Zhou Z.-H. SOM Based Image Segmentation, Lecture Notes in Artificial Intelligence 2639, Springer, 2003. – P. 640–643.
11. Reyes-Aldasoro C.C. Image Segmentation with Kohonen Neural Network Self-Organising Maps, 2004. – <http://www.cs.jhu.edu/~cis/cista/446/papers/SegmentationWithSOM.pdf>
12. Wu Y., Liu Q., Huang T.S. An Adaptive Self-Organizing Color Segmentation Algorithm with Application to Robust Real-time Human Hand Localization // Proc. Asian Conf. on Computer Vision, Taiwan, 2000.
13. Kohonen T. Self-Organizing Maps. – Springer, 2001. – 501 p.
14. Ford A., Roberts A. Colour Space Conversions, 1998. – <http://www.poynton.com/PDFs/coloureq.pdf>
15. Hunt R.W.G. Measuring Colour Fountain Pr Ltd, 1998. – 336 p.
16. Hoffmann G. CIE Lab Color Space, 2003. – <http://www.fho-emden.de/~hoffmann/cielab03022003.pdf>
17. Hoffmann G. CIE Color Space, 2000. – <http://www.fho-emden.de/~hoffmann/ciexyz29082000.pdf>
18. Highdimensional data structure analysis using Self-Organising Maps / O. Hodych, Y. Shcherbyna, Y. Nikolskyi. et. al. // CADSM 9th Intern. Conf., 19–24 Feb. 2007. – P. 218–221.

© О.В. Годич, К.Н. Гуцин, Ю.В. Никольський, В.В. Пасічник, Ю.Н. Щербина, 2009

2. Философский энциклопедический словарь / Гл. редакция: Л.Ф. Ильичева, П.Н. Федосеев, С.М. Ковалев и др. – М.: Сов. Энциклопедия, 1983. – 840 с.
3. Ивахненко А.Г. Самообучающиеся системы распознавания и автоматического управления. – Киев: Техника, 1969. – 392 с.
4. Ивахненко А.Г., Степанко В.С. Помехоустойчивость моделирования. – К.: Наук. думка, 1985. – 216 с.
5. Ивахненко А.Г., Зайченко Ю.П., Димитров В.Д. Принятие решений на основе самоорганизации. – М.: Сов. радио, 1976. – 280 с.
6. Tarakanov A.O., Skormin V.A., Sokolova S.P. Immunocomputing: principles and applications New York: Springer-Verlag, 2003. – 193 p.
7. de Castro, L.N., Von Zuben, F.J. aiNet: An artificial Immune Network for Data Analysis // Data Mining: A Heuristic Approach / Eds. H.A. Abbass, R.A. Saker, C.S. Newton, Idea Group Publ., USA, Chapter XII. – 2001. – P. 231–259.
8. Timmis J., Neal M. A resource Limited Artificial Immune System for Data Analysis. Knowledge Based Syst. – 2001. – 14(3–4)– P. 121–130.
9. Thomas Knight, Jon Timmis. AINE: An Immunological Approach to Data Mining. ICDM 2001. – P. 297–304.
10. Wierzchoc S.T. Artificial Immune Systems. Theory and Appl. Akademicka Oficyna Wydawnicza EXIT. – (Polish) Warszawa, 2001. – 282 p.
11. Ultsch A. U\*-Matrix: a Tool to Visualize Clusters in High Dimensional Data // Technical Report N 36, Department of Mathematics and Computer Science Philipps-University Marburg, 2003. – P. 290–303.
12. Adaptive radius immune algorithm for data clustering / G.B. Bezerra, T.V. Barra, L.N. de Castro et al. // Proc. of 4th Intern. Conf. on Artificial Immune Systems – ICARIS. 3627 of Lecture Notes in Comp. Sci. – New York: Springer-Verlag, 2005. – P. 290–303.

© В.И. Литвиненко, 2009