

О.В. Годыч, К.Н. Гущин, 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. Основной недостаток 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_{Luv}* и *CIE_{Lab}* – 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_{Lab}* 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_{Lab}*, которое и используем для дальнейшей обработки. Заметим, что при использовании *SOM* часто употребляют евклидово расстояние для вычисления отличия между элементами входного пространства³, необходимого для поиска нейронов наилучшего приближения [13]. Вместе с тем именно евклидово расстояние используют в просторные *CIE_{Lab}* для вычисления отличия между элементами пространства, которыми являются пиксели изображения [16]. Забегая вперед, рассмотрим рис. 1, иллюстрирующий важность выбора цветового простран-

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

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

³ 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 4×4 пикселя, представленного в пространств *CIE-Lab* и разделенного на четыре сегмента 2×2 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; v – HSL; z – 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 2×2 пикселя к изображению размером 800×600 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 λ 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 λ .

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 800×600 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
9. Akgul C.B. Cascaded self-organizing networks for color image segmentation, 2004. – 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. CIELab 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