

АНАЛИЗ ТЕКСТУР В ПОСЛЕДОВАТЕЛЬНОСТИ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ВЕКТОРНОГО КВАНТОВАНИЯ

В работе предложен подход к анализу последовательностей изображений (видеоданных). Для этих целей разработаны матричные аналоги существующих нейросетевых подходов, что позволяет учитывать пространственные связи мультимедийной информации и сократить время необходимое на обработку информации за счет введения новой матричной процедуры обучения нейронной сети. В качестве основного признака, по которому производится разбиение исходных данных, были выбраны текстуры, что в свою очередь позволяет повысить точность кластеризации.

Ключевые слова: изображение, текстура, кластеризация, матричные алгоритмы, нейронные сети.

НОМЕНКЛАТУРА

$M \times N$ – размерность изображения;

$m \times n$ – размер анализируемого блока изображения;

$x(k)$ – вектор входного сигнала;

w_q^L – центры классов при разбиении;

$\text{Sp}(\ast)$ – след матрицы;

$\eta(k)$ – параметр шага обучения;

$D(x(kn), w_q^L(kn))$ – расстояние между входными данными и центрами кластеров;

$\mu((x(k+1), w_q^L(k+1)))$ – оценка уровня принадлежности данных кластеру;

A – матрица коэффициентов размерности $(m \times m)$;

C – матрица коэффициентов размерности $(n \times n)$;

$\xi(k) = \{\xi_{i_1 i_2}(k)\}$ – матричный белый шум с ограниченной дисперсией;

h – порядок авторегрессии;

E_A^{k+1}, E_C^{k+1} – критерии оптимизации;

$V(k)$ – блочная матрица с информацией о матричной-пространственно-временной авторегрессионной модели.

ВВЕДЕНИЕ

Стремительное развитие информационных технологий естественным образом приводит к появлению больших объемов мультимедийной информации. При этом качество получаемой информации все улучшается в связи с усовершенствованием средств ее получения. В свою очередь появляется все больше задач, связанных с анализом мультимедиа информации. И если ранее исследователь мог ограничиваться в своих задачах одним или несколькими статическими изображениями, то в настоящее время для получения более эффективных алгоритмов анализа используются либо последовательности, связанных каким-либо образом, изображений, например, полученные через равные интервалы времени, либо

вообще видеоданные, которые всегда можно представить в виде последовательности кадров, а соответственно – последовательности изображений.

При этом одним из вполне естественных подходов по анализу видеопоследовательностей представляется использование математического аппарата анализа временных рядов. Они вполне могут применяться для задачи разбиения видеоданных на однородные по содержанию сегменты. С другой стороны эту же задачу можно интерпретировать как многомерную кластеризацию (сегментацию) множества изображений по неким признакам. Наряду с информацией о цвете также можно использовать текстурные признаки для проведения сегментации. Анализ текстур последовательностей изображений и посвящена данная работа.

1 ПОСТАНОВКА ЗАДАЧИ

Пусть обрабатываемое изображение задано в виде $M \times N$ – числовой матрицы, которая должна быть разбита в процессе анализа на однородные в смысле текстур классы (кластеры, сегменты). Исходная матрица разбивается на блоки размера $(m \leq M) \times (n \leq N)$, каждый из которых в рамках традиционного подхода [12] преобразуется в $(mn \times 1)$ – векторы, общее число которых равняется $MN(mn)^{-1}$. Именно этот набор и подается на входы классифицирующей нейронной сети.

2 АНАЛИЗ ЛИТЕРАТУРЫ

Анализ текстур – классификация и сегментация является важным направлением в общей теории распознавания образов и обработки изображений (Video Mining), а для его реализации к настоящему времени сложился целый ряд подходов, имеющих в своей основе различный математический аппарат. Здесь, прежде всего, следует отметить традиционный статистический подход [1, 2] методы стохастической оптимизации [3], геометрические методы [4], марковские модели [5–8], алгоритмы вэйвлет-обработки сигналов [10] и, наконец,

достаточно широкий класс искусственных нейронных сетей [9–12]. При этом авторы работы [12] подчеркивают, что нейросетевой подход может в значительной мере объединить в себе все вышеупомянутые, благодаря универсальным аппроксимирующим и фильтрующим свойствам, способности к настройке своих характеристик непосредственно в процессе обработки, восстановлению нелинейных разделяющих гиперповерхностей сложной формы. Возможности нейросетевого подхода были продемонстрированы в процессе решения набора тестовых задач классификации текстур с помощью трехслойного персептрона с 75-ю нейронами в первом скрытом слое, числом нейронов в выходном слое равным количеству возможных классов и обучаемого с помощью RPROP – алгоритма, являющегося по сути модификацией стандартного алгоритма обратного распространения ошибок (δ -правила обучения с учителем) [11]. При этом входной сигнал с окна, образованного 25 пикселями предварительно векторизуется с учетом того, что каждому пикселу ставится в соответствие три цвета. Большое количество настраиваемых синаптических весов многослойного персептрона (только в первом слое их число достигает 75^2), а также низкая скорость обучения на основе δ -правила заставляют искать иные, альтернативные многослойным архитектуры нейронных сетей, содержащие меньшее число настраиваемых параметров. Кроме того, при анализе изображений удобнее обрабатывать входную информацию не в форме вектора, а непосредственно подавать ее на обработку в виде окна-матрицы, т.е. перейти от обработки многомерных сигналов к анализу двумерных полей [13–15].

3 МАТЕРИАЛЫ И МЕТОДЫ

Классификация текстур на основе матричного векторного квантования. Нами предлагается вместо $(m \times 1)$ – векторов-образов представлять входные сигналы в форме $(m \times n)$ – матриц $x(k) = \{x_{i_1}, x_{i_2}(k)\}$, $i_1 = 1, 2, \dots, m$; $i_2 = 1, 2, \dots, n$; $k = 1, 2, \dots, MN(mn)^{-1}$ в случае $m < M$, $n < N$ или текущее дискретное время или номер изображения в базе данных при $m = M$, $n = N$. Кроме того, вместо традиционного многослойного персептрона мы предлагаем использовать нейронную сеть обучаемого векторного квантования (LVQ) [16] в матричной ее модификации [17]. Нейронные сети обучаемого векторного квантования, введенные Т. Кохоненом, основаны на идеях конкурентного обучения и имеют однослойную архитектуру, полностью совпадающую с архитектурой популярной самоорганизующейся карты. В основе этих сетей лежит техника векторного квантования, состоящая в компактном представлении больших массивов информации, заданных в виде набора векторов, а в нашем случае набора $(m \times n)$ – матриц $x(k)$, в форме ограниченного набора центров классов w_q^L , $q = 1, 2, \dots$, достаточно хорошо в смысле прямой метри-

ки разбивающих пространство входов на однородные области (текстуры), при этом w_q^L также является $(m \times n)$ – матричный, а p – это возможное число классов в обучающей выборке.

Процесс обучения с учителем в матричном VLQ происходит следующим образом. Для каждого предварительно пронормированного образа-матрицы $x(k+1)$ тако-го, что $\text{Sp}(x(k+1)x^T(k+1)) = 1$, определяется нейрон-победитель, синаптические веса которого $w_q^{L*}(k)$ соответствуют центру определенного класса-текстуры. Иначе говоря, победителем является нейрон с минимальным расстоянием до входной матрицы, т. е.

$$\begin{aligned} \text{Sp}((x(k+1) - w_q^{L*}(k))(x(k+1) - w_q^{L*}(k))^T) < \\ < \text{Sp}((x(k+1) - w_q^L(k))(x(k+1) - w_q^L(k))^T), \\ \forall q = 1, 2, \dots, p. \end{aligned}$$

Поскольку обучение является контролируемым, принадлежность матрицы $x(k+1)$ к конкретному классу известна, что позволяет проанализировать две возможные ситуации, возникающие в обучаемом векторном квантовании:

- 1) входной образ $x(k+1)$ и нейрон-победитель $w_q^{L*}(k)$ относятся к одному и тому же классу;
- 2) входной образ $x(k+1)$ и нейрон-победитель относятся к разным классам.

Тогда матричная модификация правила обучения LVQ может быть записана в виде

$$w_q^L(k+1) = \begin{cases} w_q^{L*}(k) + \eta(k+1)(x(k+1) - w_q^{L*}(k)), & \text{если } x(k+1) \text{ и } w_q^{L*}(k) \text{ принадлежат к одному классу;} \\ w_q^{L*}(k) - \eta(k+1)(x(k+1) - w_q^{L*}(k)), & \text{если } x(k+1) \text{ и } w_q^{L*}(k) \text{ принадлежат разным классам;} \\ w_q^L(k) & \text{для нейронов, не победивших в момент } k+1, \end{cases} \quad (1)$$

где $\eta(k+1)$ – параметр шага обучения, монотонно уменьшающийся в процессе настройки.

Данное правило имеет ясный физический смысл: если нейрон-победитель и предъявленный образ относятся к одному классу, то центр $w_q^{L*}(k)$ подтягивается к $x(k+1)$, перемещая при этом и границу между классами. В противном же случае центр класса $w_q^{L*}(k)$ отталкивается от $x(k+1)$, отталкивая при этом и соответствующую границу.

Особенностью задачи, связанной с обработкой изображений, является то, что в одном окне $x(k+1)$ одновременно может оказаться сразу несколько текстур относящихся к разным классам. В этом случае процедуру обучения (1) следует дополнить оценкой уровня принадлежности образа $x(k+1)$ к разным классам

$q = 1, 2, \dots, p$. Вводя расстояние между $x(k+1)$ и каждым из центров $w_q^L(k+1) \forall q$ в виде

$$D(x(kn), w_q^L(kn)) = (\text{Sp}((x(k+1) - w_q^L(k+1))(x(k+1) - w_q^L(k+1))^T))^{\frac{1}{2}},$$

можно записать оценку уровня принадлежности в виде

$$\mu((x(k+1), w_q^L(k+1))) = \frac{D^{-1}(x(k+1), w_q^L(k+1))}{\sum_{q=1}^p D^{-1}(x(k+1), w_q^L(k+1))} = \frac{(\text{Sp}((x(k+1) - w_q^L(k+1))(x(k+1) - w_q^L(k+1))^T))^{\frac{1}{2}}}{\sum_{q=1}^p (\text{Sp}((x(k+1) - w_q^L(k+1))(x(k+1) - w_q^L(k+1))^T))^{\frac{1}{2}}}. \quad (2)$$

Используя оценку (2), несложно произвести нечеткую классификацию образа, содержащего сразу несколько текстур.

Классификация текстур в последовательности изображений. Традиционно задача кластеризации текстур решается в «статическом» варианте, когда анализу подвергается единственное и неизменяемое изображение. Именно такой задаче посвящено подавляющее число публикаций по данной проблематике. В то же время достаточно интересной представляется задача классификации текстур в последовательности изображений, где сегменты этой последовательности изменяются во времени, могут появляться новые и исчезать старые текстуры. Такие текстуры называются «временными» (temporal) и изучены они явно недостаточно.

Так, в [18] предлагается каждый пиксель изображения рассматривать как линейную комбинацию предыдущих его состояний, т. е. в форме авторегрессионной модели. Вектором же признаков, на основе которого производится классификация, являются коэффициенты этих моделей. В [19] рассмотрена, так называемая, пространственно-временная авторегрессионная модель (STAR), куда включена предыстория не только конкретного пиксела, но и его окружения, заданного в форме окна. STAR – модель, описывающая пространственно-временную эволюцию текстур, полностью описывается вектором своих коэффициентов, который подается на классифицирующую систему – искусственную нейронную сеть.

С тем, что бы перейти от векторного описания к матричному, для описания эволюции двумерного поля, заданного в виде $(m \times n)$ – матрицы, $x(k)$, воспользуемся моделью, введенной в [20], вида

$$x(k) = Ax(k-1)C + \xi(k). \quad (3)$$

Поскольку описанию (3) соответствует авторегрессия первого порядка, можно ввести в рассмотрение матричную модель авторегрессии произвольного порядка h вида

$$x(k) = \sum_{d=1}^h A_d x(k-d)C_d + \xi(k) = A(x(k-1) : x(k-2) : \dots : x(k-h))C + \xi(k) = A\tilde{x}(k-1)C + \xi(k), \quad (4)$$

где $A = (A_1 : A_2 : \dots : A_h)$, $C = \begin{pmatrix} C_1 \\ \dots \\ C_2 \\ \dots \\ \dots \\ C_h \end{pmatrix}$,

$$\tilde{x}(k-1) = \begin{pmatrix} x(k-1) & & 0 \\ & x(k-2) & \\ 0 & & x(k-h) \end{pmatrix} - (hm \times hn)$$

матрица.

Несложно заметить, что модель (4) является обобщением выражения (3) и совпадает с ним при $h = 1$.

Для определения $(m \times hm)$ и $(hn \times n)$ – матриц коэффициентов A и C можно воспользоваться адаптивным оптимальным градиентным алгоритмом идентификации матричных моделей [21] минимизирующим критерий

$$E_A^{k+1} = \text{Sp}(x(k+1) - A(k)\tilde{x}(k)C(k))(x(k+1) - A(k)\tilde{x}(k)C(k))^T = \text{Sp}V_A(k+1)V_A^T(k+1) = \|V_A(k+1)\|^2, \\ E_C^{k+1} = \text{Sp}(x(k+1) - A(k+1)\tilde{x}(k)C(k))(x(k+1) - A(k+1)\tilde{x}(k)C(k))^T = \text{Sp}V_C(k+1)V_C^T(k+1) = \|V_C(k+1)\|^2.$$

и имеющим вид

$$\begin{cases} A(k+1) = A(k) + (\text{Sp}V_A(k+1)C^T(k)\tilde{x}^T(k)\tilde{x}(k) \times \\ \times C(k)V_A^T(k+1))(\text{Sp}V_A(k+1)C^T(k)\tilde{x}^T(k) \times \\ \times (k)\tilde{x}(k)C(k)C^T(k)\tilde{x}^T(k)\tilde{x}(k)C(k)V_A^T(k+1))^T \times \\ \times V_A(k+1)C(k)\tilde{x}^T(k), \\ C(k+1) = C(k) + (\text{Sp}V_C^T(k+1)A(k+1)\tilde{x}(k)\tilde{x}^T(k) \times \\ \times A^T(k+1)V_C(k+1))(\text{Sp}A(k+1)\tilde{x}(k)\tilde{x}^T(k) \times \\ \times (k)A^T(k+1)V_C(k+1)V_C^T(k+1)A(k+1)\tilde{x}(k)\tilde{x}^T(k) \times \\ \times (k+1)\tilde{x}^T(k)A^T(k+1)V_C(k+1)). \end{cases} \quad (5)$$

Можно также заметить, что фактически алгоритм (5) является матричным обобщением популярного алгоритма Уидроу-Хоффа [11], используемом при обучении искусственных нейронных сетей.

Объединяя матрицы коэффициентов $A(k+1)$, $C(k+1)$, получаем $(m+hn) \times (hm+n)$ блочную матрицу

$$B(k+1):B(k+1) = \begin{pmatrix} A(k+1) & \vdots & O \\ \dots & \vdots & \dots \\ O & \vdots & C(k+1) \end{pmatrix},$$

содержащую в себе полную информацию о матричной-пространственно-временной авторегрессионной модели. Именно эта матрица подается на вход матричной VLQ-системы. При этом алгоритм обучения приобретает вид

$$w_q^L(k+1) = \begin{cases} w_q^{L*}(k) + \eta(k+1)(B(k+1) - w_q^{L*}(k)); & \text{если } B(k+1) \text{ и } w_{q1q2}^{L*}(k) \text{ принадлежат одному классу,} \\ w_q^{L*}(k) - \eta(k+1)(B(k+1) - w_q^{L*}(k)); & \text{если } B(k+1) \text{ и } w_q^{L*}(k) \text{ принадлежат разным классам,} \\ w_q^L(k) & \text{для нейронов, не победивших в момент } k+1. \end{cases}$$

Несложно также записать и оценку уровней принадлежности в случае проведения нечеткой классификации:

$$\mu(B(k+1), w_q^L(k+1)) = \frac{D^{-1}(B(k+1), w_q^L(k+1))}{\sum_{q=1}^p D^{-1}(B(k+1), w_q^L(k+1))} = \frac{(\text{Sp}((B(k+1) - w_q^L(k+1))(B(k+1) - w_q^L(k+1))^T))^{-\frac{1}{2}}}{\sum_{q=1}^p (\text{Sp}((B(k+1) - w_q^L(k+1))(B(k+1) - w_q^L(k+1))^T))^{-\frac{1}{2}}}$$

4 ЭКСПЕРИМЕНТЫ

Экспериментальный анализ предложенной классифицирующей нейронной сети проводился с видеопоследовательностями, состоящими из 2250 изображений в формате RGB с прогрессивной разверткой и разрешением 640 на 416 точек. Для элиминации влияния любого возможного сжатия использовались изображения в формате .BMP. Иначе говоря, в контейнерах .AVI были представлены 90-секундные видеоряды (всего 10), для которых интерактивно определены границы сегментов, т.е. однородных по «содержанию» последовательностей видеок кадров. Рис. 1 иллюстрирует левую и правую гра-

ницы сегмента, состоящего из 75 видеок кадров (лесные пожары, National Geographic), для которых текстурные признаки являются максимально репрезентативными. Для различных видео число сегментов составляло 20–25 семантически однородных подпоследовательностей. При этом длина обучающей выборки варьировалась от 40 до 350 фрагментов. В вычислительном эксперименте число фрагментов составляло: 256 (блоки – 40×26 элементов), 64 (блоки – 80×52 элемента), 16 (блоки – 120×104 элемента).

На рис. 2 показано представление среднего изображения рис. 1 16 блоками.

5 РЕЗУЛЬТАТЫ

Результаты экспериментов позволяют утверждать, что для случаев четкой визуальной границы между темпоральными сегментами классифицирующая нейронная сеть обеспечивает 100 % определение сегментов при любых размерах фрагментов. Однако увеличение числа фрагментов нередко приводит к тому, что при «плавном» (например, медленном панорамировании или искусственных эффектах типа «растворение») переходе от сегмента к сегменту возникают ложные «блоковые» границы, не соответствующие семантике видео. Данный эффект иллюстрируется рис. 3 (цунами 11 сентября 2011 г. в Японии, NHK), на котором приведен сегмент с шагом 50 видеок кадров. С одной стороны, избежать ошибок можно добавлением признаков или, используя пирамидальное представление изображений, стратифицированным огрублением (понижением разрешающей способности) изображений. С другой стороны, при рациональных размерах фрагментов получаем инструмент для более детальной сегментации видео, когда во внимание принимаются локальные изменения сюжета. В целом, классифицирующая нейронная сеть на базе анализа текстур при блочном представлении видео является достаточно перспективным инструментарием для систем поиска видеоданных по их содержанию.

ВЫВОДЫ

В статье предложен подход к кластеризации статических и динамических текстур в последовательности изображений с помощью обучаемого векторного квантования. Введен алгоритм обучения нейронной сети в матричном варианте, что позволяет сократить время обработки и анализировать изображение в целом. Развиваемый подход отличается численной простотой и быстродействием.



Рисунок 1 – Пример границ сегментов видеопоследовательностей




Рисунок 2 – Представление изображения блоками



Рисунок 3 – Пример ложных границ сегментов

БЛАГОДАРНОСТИ

Работа выполнена в рамках госбюджетной темы Харьковского национального университета радиоэлектроники «Нейро-фаззи системы для текущей кластеризации и классификации последовательностей данных в условиях их искривленности отсутствующими и аномальными наблюдениями» (№ ДР 0113U000361).

СПИСОК ЛИТЕРАТУРЫ

- Derin H. Modeling and segmentation of noisy and textured images using Gibbs random fields / H. Derin, H. Elliot // *IEEE Trans. on Pattern Analysis and Machine Intelligence*. – 1987. – Vol. 9. – P. 39–55.
- Varma M. A statistical approach to texture classification from single images / M. Varma, A. Zisserman // *Int. J. of Computer Vision*. – 2005. – Vol. 62. – P. 61–81.
- Liu L. Texture classification from random features / L. Liu, P. Fieguth // *IEEE Trans. on Pattern Analysis and Machine Intelligence*. – 2012. – No. 34. – P. 574–586.
- Chen Y. Q. Statistical geometrical features for texture classification / Y. Q. Chen, M. S. Nixon, D. W. Thomas // *Pattern Recognition*. – 1995. – No. 28. – P. 537–552.
- Cross G. R., Jain A.K. Markov random field texture models / G. R. Cross, A. K. Jain // *IEEE Trans. on Pattern Analysis and Machine Intelligence*. – 1983. – No. 5. – P. 25–39.
- Chellapa R. Classification of textures using Gaussian – Markov random fields / R. Chellapa, S. Chatterjee // *IEEE Trans. on Acoust., Speech, Signal Processing*. – 1985. – No. 33. – P. 959–963.
- Ghahramani Z. An introduction to hidden Markov models and Bayesian networks / Z. Ghahramani // *Int. J. of Pattern Recognition and Artificial Intelligence*. – 2001. – No. 15. – P. 9–42.
- Beal M. J. The infinite hidden Markov model / M. J. Beal, Z. Ghahramani, C. E. Rasmussen // *Neural Information Processing Systems*. – 2001. – P. 577–584.
- Neural Networks for Signal Processing* / ed. B. Kosko. – New Jersey : Prentice Hall, 1992. – 399 p.
- Rojas R. *Neural Network: A Systematic Introduction* / R. Rojas. – Berlin : Springer-Verlag. 1996. – 502 p.
- Хайкин С. Нейронные сети: Полный курс / С. Хайкин. – М. : Издательский дом Вильямс, 2006. – 1104 с.
- Raveane W. Texture classification with neural networks / W. Raveane, M.A.G. Arrieta ; eds. Omatu et. al. // *Distributed Computing&Artificial Intelligence*. – Berlin, Springer, 2013. – P. 305–332.
- Caldas-Pinto J. R. Self-tuning filters and predictors for two-dimensional systems / J. R. Caldas-Pinto, P. E. Wellstead // *Int. J. of Control*. – 1985. – Vol. 42, No. 2. – P. 457–505.
- Wellstead P. E. Two-dimensional adaptive prediction, smoothing and filtering / P. E. Wellstead, G. R. Wagner, J. R. Caldas-Pinto // *IEE Proc.* – 1987. – No. 3. – P. 253–267.
- Bodyanskiy Ye. Discrete adaptive identification and extrapolation of two-dimensional fields / Ye. Bodyanskiy, I. Pliss, V. Timofeev // *Pattern Recognition and Image Analysis*. – 1995. – No. 3. – P. 410–416.
- Kohonen T. *Self-organizing maps* / T. Kohonen. – Berlin : Springer Verlag, 1995. – 362 p.

17. Богучарский С.И. Обработка изображений на основе комбинированного векторного квантования с использованием полуконтролируемого обучения / Богучарский С. И. // Вестник НТУ «ХПИ». – 2014. – № 6 (1049). – С. 20–29.
18. Mao J. Texture classification and segmentation using multiresolution simultaneous autoregressive models / J. Mao, A. K. Jain // Pattern Recognition. – 1992. – No. 25. – P. 173–188.
19. Ardizzone E. Using temporal texture for content-based video retrieval / E. Ardizzone, A. Capra, M. La Cascia // Journal of Visual Languages and Computing. – 2000. – No. 11. – P. 241–252.
20. Кунцевич В.М. О решении задачи двумерной дискретной фильтрации // Автоматика и телемеханика. – 1987. – № 6. – С. 68–78.
21. Бодянский Е.В. О решении задачи управления матричным объектом в условиях неопределенности / Е. В. Бодянский, И. П. Плисс // Автоматика и телемеханика. – 1990. – No. 2. – С. 175–178.

Статья поступила в редакцию 17.09.2014.
После доработки 20.10.2014.

Богучарський С. І.¹, Машталір С. В.²

¹Аспірант, Харківський національний університет радіоелектроніки, Україна

²Канд. техн. наук, доцент, Харківський національний університет радіоелектроніки, Україна

АНАЛІЗ ТЕКСТУР В ПОСЛІДОВНОСТЯХ ЗОБРАЖЕНЬ НА БАЗІ ВЕКТОРНОГО КВАНТУВАННЯ

В роботі запропонований підхід до аналізу послідовностей зображень (відеоданих). Для цього розроблені матричні аналоги існуючих неймережових підходів, що дозволяє враховувати просторові зв'язки мультимедійної інформації та скоротити час необхідний на обробку інформації за рахунок введення нової матричної процедури навчання нейронної мережі. В якості базової ознаки, за якою проводиться розбиття вихідних даних, було обрано текстурі, що в свою чергу дозволяє підвищити точність кластеризації.

Ключові слова: зображення, текстурі, кластеризація, матричні алгоритми, нейронні мережі.

Bogucharskiy S. I.¹, Mashtalir S. V.²

¹Postgraduate student, Kharkiv National University of Radio Electronics, Ukraine

²Ph.D., Associate Professor, Kharkiv National University of Radio Electronics, Ukraine

IMAGE SEQUENCES TEXTURE ANALYSIS BASED ON VECTOR QUANTIZATION

The approach for the image sequence (videodata) analysis is proposed. For this purpose, the matrix analogs of existing neural network approaches is developed. This allows to take into account the spatial relationships of multimedia information, and to reduce the time of information processing through the introduction of a new neural network matrix training procedures.

The texture is selected as a basic characteristic for original data partition, which, in turn, improves the clustering accuracy.

Keywords: image, texture, clustering, matrix algorithm, neural networks.

REFERENCES

1. Derin H., Elliot H. Modeling and segmentation of noisy and textured images using Gibbs random fields, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1987, No. 9, pp. 39–55.
2. Varma M., Zisserman A. A statistical approach to texture classification from single images, *Int. J. of Computer Vision*, 2005, No. 62, pp. 61–81.
3. Liu L., Fieguth P. Texture classification from random features, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2012, No. 34, pp. 574–586.
4. Chen Y. Q., Nixon M. S., Thomas D. W. Statistical geometrical features for texture classification, *Pattern Recognition*, 1995, Vol. 28, pp. 537–552.
5. Cross G. R., Jain A. K. Markov random field texture models, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1983, No. 5, pp. 25–39.
6. Chellapa R., Chatterjee S. Classification of textures using Gaussian-Markov random fields, *IEEE Trans. on Acoust., Speech, Signal Processing*, 1985, Vol. 33, pp. 959–963.
7. Ghahramani Z. An introduction to hidden Markov models and Bayesian networks, *Int. J. of Pattern Recognition and Artificial Intelligence*, 2001, No. 15, pp. 9–42.
8. Beal M. J., Ghahramani Z., Rasmussen C. E. the infinite hidden Markov model, *Neural Information Processing Systems*, 2001, pp. 577–584.
9. Neural Networks for Signal Processing / Ed. by B. Kosko, Englewood Cliffs, New Jersey, Prentice Hall, 1992, 399 p.
10. Rojas R. Neural Network: A Systematic Introduction. Berlin, Springer-Verlag, 1996, 502 p.
11. Haikin S. Neironnie seti: Polniy kurs. Moscow, Izdatelskiy dom «Wilyams», 2006, 1104 p.
12. Raveane W., M.A.G. Arrieta ; Eds. Omatu et. al. Texture classification with neural networks, *Distributed Computing & Artificial Intelligence*. Berlin, Springer, 2013, pp. 305–332.
13. Caldas-Pinto J. R., Wellstead P. E. Self-tuning filters and predictors for two-dimensional systems, *Int. J. of Control*, 1985, Vol. 42, No. 2, pp. 457–505.
14. Wellstead P. E., Wagner G. R., Caldas-Pinto J. R. Two-dimensional adaptive prediction, smoothing and filtering, *IEE Proc*, 1987, No. 3, pp. 253–267.
15. Bodyanskiy Ye, Pliss I., Timofeev V., Discrete adaptive identification and extrapolation of two-dimensional fields, *Pattern Recognition and Image Analysis*, 1995, No. 3, pp. 410–416.
16. Kohonen T. Self-organizing maps. Berlin, Springer Verlag, 1995, 362 p.
17. Bogucharskiy S. I. Obrabotka izobrazheniy na osnove kombinirovannogo vektornogo kvantovaniya s ispolzovaniem polukontroliruемого obucheniya, *Vestnik NTU «KhPI»*, 2014, No. 6 (1049), pp. 20–29.
18. Mao J., Jain A. K. Texture classification and segmentation using multiresolution simultaneous autoregressive models, *Pattern Recognition*, 1992, No. 25, pp. 173–188.
19. Ardizzone E., Capra A., La Cascia M. Using temporal texture for content-based video retrieval, *Journal of Visual Languages and Computing*, 2000, No. 11, pp. 241–252.
20. Kunzevich V. M. O reshenii zadachi dvumernoy diskretnoy filtracii, *Avtomatika i telemehanika*, 1987, No. 6, pp. 68–78.
21. Bodyanskiy Ye. V., Pliss I. P. O reshenii zadachi upravleniya matrichnim obyektom v usloviyah neopredelennosti, *Avtomatika i telemehanika*, 1990, No. 2, pp. 175–178.