

УДК 621.3:681.34

С. С. КРИВЕНКО, А. В. НАУМЕНКО, В. В. ЛУКИН

*Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», Украина***ОБНАРУЖЕНИЕ ТЕКСТУРНЫХ УЧАСТКОВ SVM-КЛАССИФИКАТОРОМ НА ИЗОБРАЖЕНИЯХ ПРИ НАЛИЧИИ ПОМЕХ**

*Рассмотрена возможность применения SVM-классификатора для обнаружения текстурных участков на изображениях, на которых присутствует достаточно интенсивный аддитивный шум. Показано, что эффективность такого классификатора зависит от количества входных признаков и размера блока, в которых эти признаки вычисляются. Также продемонстрирована применимость обученного классификатора для обработки изображений с различными текстурами и при разном уровне помех. Показано, что для четырех полностью текстурных тестовых изображений достигается уровень чувствительности классификатора на уровне 0,85-0,95.*

**Ключевые слова:** текстура, обнаружение, изображение, помехи, обучение.

**Введение**

Текстуры являются одним из характерных элементов изображений [1, 2]. Текстурные признаки широко используют при сегментации изображений [3-5], классификации материалов [6, 7] и типов поверхностей по изображениям дистанционного зондирования (ДЗ) [8], для поиска изображений по подобию в базах большого размера [9], компьютерной графики и т.д. При этом существуют и в той или иной мере решены различные задачи обнаружения текстурных участков. Например, часто желательнее обнаружить текстурный участок или участки, для которых есть эталон или набор текстурных признаков [10, 11]. Однако есть приложения, когда необходимо обнаружить и определить границы (оконтурить) текстурных участков при отсутствии априорных сведений о признаках текстур [8, 12]. Такая задача, в частности, возникает при необходимости оценить текстурные признаки, чтобы затем использовать их при классификации объектов [12, 13].

Одна из проблем при применении указанных выше видов обработки и анализа состоит в том, что исходные изображения могут быть искажены помехами (аддитивными, сигнально-зависимыми, мультипликативными в зависимости от типа изображений [14-20]). Присутствие помех затрудняет обнаружение текстурных участков [14] и извлечение (оценивание) текстурных признаков, снижает визуальное качество изображений в целом и текстурных участков в частности [17]. В связи с этим часто применяют фильтрацию изображений с целью подавления помех. Однако подавление помех на текстурных участках является проблематичным для большинства известных фильтров, включая наиболее современные и эффективные [21]. Даже фильтр

BM3D [22], который на данный момент является наиболее эффективным при подавлении аддитивного белого гауссова шума, лишь немного подавляет помехи и улучшает визуальное качество текстурных изображений [17, 21], незначительно превосходя более простые фильтры, например, фильтр на основе дискретного косинусного преобразования (ДКП) [23], показавший себя одним из лучших в плане сохранения текстуры [14, 17].

Здесь необходимо отметить следующее. Как сказано выше, даже наилучшие фильтры не приводят к заметному подавлению помех на текстурных участках. Возможно, иногда целесообразно вообще не подвергать такие участки фильтрации, поскольку обработанные фильтром текстурные участки часто выглядят «смазанными». Во-вторых, для многих методов фильтрации при обработке текстурных участков используют локально-адаптивный подход [14-16, 19, 20], в соответствии с которым для однородных и неоднородных (текстурных, окрестностей границ и малоразмерных объектов) участков используют разные фильтры или фильтры с разными параметрами.

Такой подход обычно приносит успех, но для текстур и окрестностей границ целесообразно применять разные фильтры [14]. В связи с этим желательнее распознавать (обнаруживать) текстурные участки, не путая их с другими типами неоднородностей (границ, малоразмерных объектов и их окрестностей).

Особенность этой задачи состоит в том, что нужно обнаруживать разные текстурные участки, не имея априорной информации о текстурных признаках для них. Как следует из работы [14], это нелегкая задача. Используемые для ее решения два локальных параметра (локальная дисперсия и квази-

размах, нормированные с учетом полагаемых априорно известных параметров помех), а также пост-обработка бинарных полей этих параметров не всегда справляются с поставленной целью.

Учитывая, что статистика коэффициентов ДКП в блоках способна, так или иначе, характеризовать текстуру [17], идея состоит в том, что совместное использование трех параметров, описывающих текстурные признаки с разных сторон, способно улучшить обнаружение текстурных участков. Ниже рассматривается один из возможных путей совместной обработки – на основе машины опорных векторов [24] (support vector machine – SVM), показавшей себя в последние годы одним из наиболее эффективных классификаторов [25].

Цель статьи – разработать классификатор «текстура – не текстура», способный работать при достаточно интенсивных помехах и проанализировать его свойства.

### Предварительная подготовка данных для классификатора

Будем предполагать, что классификация выполняется попиксельно, то есть решение о принадлежности данного (рассматриваемого) пикселя классу «Текстура» или «Не текстура» выполняется на основе применения заранее обученного классификатора к набору входных признаков, рассчитанных для скользящего окна, центр которого совпадает с данным пикселем.

Также положим, что обучение классификатора выполняется заранее, off-line. Для формирования обучающей выборки для классификатора нами были использованы различные наборы значений нескольких локальных параметров. Под локальностью в данном случае подразумевается то, что эти параметры вычисляются в т.н. скользящих окнах небольшого размера: в данном случае были получены и рассмотрены результаты для скользящих окон размера 5x5, 7x7 и 9x9 пикселей. Рассматриваемые локальные параметры выбраны и применены, исходя из следующих соображений:

- различные локальные параметры проявляют себя с неодинаковой эффективностью при детектировании текстурных участков [14];

- используемые параметры базируются на нескольких различных признаках и принципах детектирования границ (или неоднородностей), что позволяет классификатору быть более универсальным по отношению к свойствам обрабатываемых данных.

Набор используемых параметров определен экспериментально и включает следующие параметры.

1. Нормированная (относительная) локальная дисперсия (ОЛД):

$$\delta_{ij} = \frac{\sigma_{ij}^2}{\sigma_{add}^2}, \quad (1)$$

где  $\sigma_{ij}^2$  – локальная дисперсия, рассчитанная в скользящем окне;

$\sigma_{add}^2$  – дисперсия аддитивного шума, присутствующего на изображении (полагается некоррелированным, имеющим нулевое математическое ожидание и известную или точно оцененную дисперсию).

Этот параметр чувствителен к слабоконтрастным неоднородным участкам и имеет значительно большие значения в скользящем окне, попавшем на границу или текстуру, чем в окне, попавшем на однородный участок.

2. Квазиразмах (КР) (для случая присутствия аддитивной помехи с учетом нормировки)

$$QR_{ij} = (I_{ij}^{(q)} - I_{ij}^{(p)}) / \sigma_{add}, \quad (2)$$

где  $I_{ij}^{(q)}$  и  $I_{ij}^{(p)}$  – соответственно q-я и p-я порядковые статистики ранжированной выборки. Значения параметров q и p выбираются эмпирически в зависимости от характера присутствующих на изображении помех. В настоящих опытах эти значения были установлены равными 23 и 3, 45 и 5, 72 и 10, соответственно (то есть  $q \approx 0,9N$  и  $p \approx 0,1N$ , где N – общее число пикселей, принадлежащих скользящему окну,  $q+p=N+1$ ). Данный параметр ведет себя подобно относительной локальной дисперсии, робастно характеризуя масштаб данных в скользящем окне.

3. Детектор на основе дискретного косинусного преобразования (ДКП), основан на следующем принципе. В скользящем окне вычисляется ДКП. После этого рассчитывается количество коэффициентов ДКП  $N_{DCT}$ , превысивших порог, который в рассматриваемых опытах был выбран равным  $2\sigma_{add}$ . Данный параметр (может быть нормирован на число пикселей в блоке N) работает в спектральной области и учитывает тот момент, когда для текстур обычно характерно присутствие достаточного количества относительно явно выраженных пространственных спектральных компонент.

Выбор значений порогов или способов нормировки для рассчитываемых локальных параметров связан с типом помех, присутствующих на обрабатываемом изображении. Случай аддитивных помех рассматривается как наиболее простой и общий, но

для сигнально-зависимых или мультипликативных помех несложно изменить нормировку.

В качестве обучающего было использовано изображение Barbara (рис. 1а), искаженное аддитивным Гауссовым шумом с нулевым средним и среднеквадратическим отклонением (СКО), равным 5. Особенностью этого тестового изображения является то, что для него относительно легко можно в интерактивном режиме выделить области, которые человек считает текстурными, то есть сформировать наборы пикселей, соответствующих классам «Текстура» и «Не текстура».

Использовался классификатор на базе машины опорных векторов (support vector machine, SVM). Этот классификатор требует предварительного обучения на заранее размеченном наборе данных. Поэтому для каждой точки входного изображения с координатами  $[x; y]$  формировался вектор входных признаков  $F$ , состоящий из точек с такими же координатами  $[x; y]$  в матрицах локальных параметров. Этому вектору  $F$  сопоставлялся признак  $S$ , определяемый по формуле:

$$S = \begin{cases} -1, & \text{нетекстура,} \\ 1, & \text{текстура.} \end{cases} \quad (3)$$

При этом вектор  $F$  был представлен в трех вариантах:  $F1=[\text{ОЛД КР}]$ ,  $F2=[\text{ДКП}]$ ,  $F3=[\text{ОЛД КР ДКП}]$ , где, например, для точки вектора  $F1$  соответствовали точки локальных параметров ОЛД и КР. Соответственно были обозначены и классификаторы. Например,  $F1\_5 \times 5$  означает использование вектора свойств  $F1$  для окна  $5 \times 5$  пикселей.

### Результаты классификации


Как уже отмечалось, изображение Barbara было предварительно вручную размечено (рис.1б). Красный цвет соответствовал текстурным участкам. Остальные участки считались нетекстурными. Размер обучающей выборки был равен 1000 элементов (1000 пар  $F-S$ ), а размер двух тестовых выборок равен 500 элементов. Следует напомнить, что тестовые выборки никак не были задействованы в процессе обучения классификатора и использовались нами для оценки эффективности классификатора и его прогностических свойств.

Для анализа эффективности классификатора был использован стандартный ROC-анализ [26]. Ключевыми показателями ROC-анализа являются чувствительность (вероятность правильного обнаружения текстур, TPR), специфичность (вероятность правильного обнаружения нетекстур, SPC), точность (вероятность корректной классификации тек-

стур и нетекстур, ACC) и коэффициент корреляции Мэттью (MCC). При этом рассматривались результаты только для тестовых выборок, т.к. для обучающей выборки значения вероятностей стремились к 100%. Ниже приведена таблица 1 сравнительного анализа показателей для полученных классификаторов.



а



б

Рис. 1. Изображение Barbara: а – исходное; б – зашумленное с СКО=5 (красным помечены области текстур)

Анализ значений ACC в случае вычисления локальных параметров в окне  $5 \times 5$  и их обработке классификатором приводит к следующим заключениям. Значения точности классификатора  $F1\_5 \times 5$  (на основе ОЛД и КР) составляют 79% для обоих тестовых наборов. Это на 2-3% хуже, чем для простейшего классификатора  $F2\_5 \times 5$ , который работает на основе ДКП. Следовательно, классификатор на основе ДКП весьма эффективен даже сам по себе. Вместе с тем, использование всех трех локальных параметров

в классификаторе F3\_5x5 приводит к увеличению точности классификатора до 83-85%. При этом величина ошибки первого рода (1-TPR) составляет 7-9%, а величина ошибки второго рода (1-SPC) – 14%, то есть текстуры обнаруживаются лучше (более надежно), чем не текстуры.

Таблица 1

Сравнительный анализ классификаторов на основе изображения Varbaga, искаженного шумом с СКО=5

Классификатор	Тестовый набор №1			
	TPR	SPC	ACC	MCC
F1_5x5	0,91	0,67	0,79	0,59
F2_5x5	0,84	0,80	0,82	0,65
F3_5x5	0,93	0,76	0,85	0,70
F1_7x7	0,85	0,74	0,80	0,59
F2_7x7	0,84	0,75	0,80	0,59
F3_7x7	0,85	0,82	0,84	0,68
F1_9x9	0,86	0,72	0,79	0,59
F2_9x9	0,83	0,81	0,82	0,64
F3_9x9	0,82	0,86	0,84	0,67
	Тестовый набор №2			
F1_5x5	0,90	0,68	0,79	0,60
F2_5x5	0,87	0,75	0,80	0,62
F3_5x5	0,91	0,76	0,83	0,68
F1_7x7	0,86	0,72	0,79	0,59
F2_7x7	0,88	0,72	0,79	0,60
F3_7x7	0,85	0,82	0,83	0,66
F1_9x9	0,87	0,75	0,81	0,62
F2_9x9	0,81	0,80	0,80	0,60
F3_9x9	0,80	0,86	0,83	0,65

Результаты анализа для других размеров скользящих окон (7x7 и 9x9 пикселей) подобны результатам анализа для окон 5x5. Снова значения ACC оказываются больше для классификатора F3, использующего все три признака (локальных параметра). Значения ACC примерно одинаковы для всех трех анализируемых размеров скользящих окон, но значения TPR и MCC для больших окон хуже. Поэтому, судя по полученным данным, не следует использовать слишком большие окна.

Для любого классификатора важно проверить, как он работает для данных, для которых его обучение не проводилось. Ниже представлены результаты работы классификаторов для изображений Varbaga для шума с СКО=5 и СКО=10 (случай представляет интерес, поскольку уровень шума заметно иной) и Baboon для шума с СКО=5 (случай представляет интерес, поскольку характеристики текстуры совсем другие) и СКО=10 (и текстура другая, и уровень помех). Анализ результатов на рис. 2 для F1\_5x5 показывает, что параллельно с хорошим обнаружением текстур (рис. 2,а и 2,в), классификатор оши-

бочно «считает» текстурами и разнообразные неоднородности – границы и их окрестности, малоразмерные объекты и их окрестности. Это и неудивительно: ведь ОЛД и КР – это, в первую очередь, обнаружители границ [14].

Интересная особенность наблюдается при обнаружении текстурных участков для изображений с СКО=10 (рис. 2,б и 2,г). Очевидно, что участки со слабой (малоконтрастной) текстурой уже не обнаруживаются (обратите внимание на часть скатерти на столе и свисающей со стола на рис. 2,б). На рис. 3 приведены результаты применения классификатора F3\_5x5. Этот классификатор заметно реже распознает границы объектов (ножка стола на рис. 3,а и 3,б) как текстуру (по сравнению с классификатором F1\_5x5, рис. 2,а и 2,б). Проблемы остаются с обнаружением слабоконтрастной текстуры. Вместе с тем, разработанный классификатор, будучи обученным для одного типа текстуры, хорошо работает и для других текстур (см. результаты для второго тестового изображения Baboon), в том числе и при другом уровне помех. Для тестирования работоспособности полученного классификатора были использованы четыре тестовых изображения, представляющие собой полностью текстурные изображения (рис. 4 а,б,в,г, изображения взяты из электронного каталога образцов текстур). Таким образом, идеальный классификатор должен обеспечивать значение TPR для каждого из изображений равным 1. К исходным изображениям был искусственно добавлен шум с СКО соответственно 5 и 10.

Таблица 2

Анализ классификаторов с использованием тестовых изображений (рис. 4), искаженных шумом с СКО=5

Классификатор	СКО = 5			
	TPR, а	TPR, б	TPR, в	TPR, г
F1_5x5	0,99	0,92	0,97	0,99
F2_5x5	0,99	0,92	0,97	0,96
F3_5x5	0,99	0,95	0,98	0,98

Таблица 3

Анализ классификаторов с использованием тестовых изображений (рис. 4), искаженных шумом с СКО=10

Классификатор	СКО = 10			
	TPR, а	TPR, б	TPR, в	TPR, г
F1_5x5	0,94	0,57	0,71	0,61
F2_5x5	0,89	0,52	0,68	0,53
F3_5x5	0,94	0,62	0,78	0,67

Ввиду отсутствия предварительно подготовленной карты текстур для изображений предполагалось, что процент текстур составляет 100%. Поэтому

му показатель TPR определялся как отношение корректно классифицированных пикселей к общему количеству пикселей (размер изображений – 512x512 пикселей). Показаны результаты для окна 5, т.к. исходя из анализа результатов для изображения Barbara (см. выше), именно этот размер окна дает наименьшую ошибку классификации среди представленных размеров окон. Анализ данных в таблице 2 показывает, что классификатор, в целом, работает даже лучше, чем для тестовых данных изображения Barbara. Совместное использование трех входных параметров на входе классификатора приводит, как правило, к большим значениям TPR, чем при использовании одного или двух входных параметров. Этот же эффект имеет место и при СКО, равном 10 (см. данные в табл. 3). Кроме того, ана-

лиз данных в таблице 3 показывает, что классификатор при СКО=10 работает заметно хуже, чем для тестовых данных. Этому есть логичное объяснение. Для обучения были использованы данные, искаженные шумом с СКО=5, поэтому изображения, искаженные шумом с другим СКО, значительно отличающимся от присутствующего в обучающих данных, будут классифицированы хуже.

Выходом из данной ситуации, который планируется проанализировать в будущем, может быть добавление в обучающую выборку фрагментов разных текстурных изображений, искаженных шумом с различным СКО. Фактически одним из направлений дальнейших исследований является совершенствование методики обучения классификатора.




Рис. 2. Классификатор F1\_5x5: а – Barbara, СКО=5; б – Barbara, СКО=10; в – Baboon, СКО=5; г – Baboon, СКО=10




Рис. 3. Классификатор F3\_5x5: а – Barbara, СКО=5; б – Barbara, СКО=10; в – Baboon, СКО=5; г – Baboon, СКО=10

### Выводы

В ходе исследования было показано, что наилучший результат для классификации текстур на изображении дает одновременное использование локальных параметров относительной локальной дисперсии, квазиразмаха и параметра на основе дискретного косинусного преобразования. Чуть лучшие результаты получены при размере окна, в котором вычислялись параметры, равном 5x5. Следующим этапом исследования может стать усовершенствование алгоритма обучения классификатора или использование других мощных классификаторов (таких как Decision Trees или AdaBoost). Кроме этого, можно исследовать агрегирование входных параметров классификатора в скользящем окне, что, предположительно, должно существенно улучшить качество классификации.

### Литература

1. Pratt, W. K. *Digital Image Processing. Fourth Edition [Text]* / W. K. Pratt. – Wiley-Interscience, 2007. – 1429 p.
2. Haralick, R. M. *Textural features for image classification [Text]* / R. M. Haralick, K. Shanmugam, I. Dinstein // *IEEE Trans. Syst., Man, Cybern.* – 1973. – Vol. 3, № 6. – P. 610 – 621.
3. *Contour and texture analysis for image segmentation [Text]* / J. Malik, S. Belongie, T. Leung, J. Shi // *IJCV.* – 2001. – Vol. 7, № 5. – P. 27–31.
4. Бевз, Е. Г. *Алгоритмы сегментации для задач текстурного анализа с применением метода синтаксического описания текстур [Текст]* / Е. Г. Бевз // *БГУИР.* – 2011. – Т. 8, № 62. – С. 9 – 13.
5. Крылов, В. Н. *Частотно-детекторный метод текстурной сегментации изображений [Текст]* / В. Н. Крылов, М. В. Полякова // *Информационно-измерительные системы.* – 2005. – № 2. – С. 3 – 8.




Рис. 4. Полностью текстурные тестовые изображения

6. Leung, T. Representing and recognizing the visual appearance of materials using three-dimensional textons [Text] / T. Leung, J. Malik // *Intl. Journal of Computer Vision*. – 2001. – № 43. – P. 29 – 44.

7. On the significance of real-world conditions for material classification [Text] / E. Hayman, B. Caputo, M. Fritz, J. Eklundh // *Computer Vision: proc. 8th European Conf. on Computer Vision*. – Prague, 2004. – Vol. 4. – P. 253 – 266.

8. Datcu, M. Multiresolution analysis of SAR images [Text] / M. Datcu, D. Luca, K. Seidel // *Remote Sensing: proc. European Conference on Synthetic Aperture Radar*. – Konigswinter, 1996. – Vol. 3. – P. 375 – 378.

9. Applying texture and color features to natural image retrieval [Text] / M. Partio, E. Guldogan, O. Guldogan, M. Gabbouj // *Signal Processing: in Proc. Finnish Signal Processing Symposium*. – Tampere, 2003. – Vol. 4. – P. 199 – 203.

10. Micusik, B. Supervised texture detection in images [Text] / B. Micusik, A. Hanbury // *Signal Processing: proceedings of 11-th International Conference on Computer Analysis of Images and Patterns*. – Versailles, France, 2005. – P. 441 – 448.

11. Texture analysis based on the bidimensional empirical mode decomposition with gray-level co-

occurrence models [Text] / J. C. Nunes, O. Niang, Y. Bouaoune, E. Delechelle, Ph. Bunel // *Signal Processing: proc. 7th International Symposium on Signal Processing and Its Application*. – 2003. – Vol. 2. – P. 633 – 635.

12. Image processing with texture feature preservation by three-state locally adaptive filter [Text] / V. V. Lukin, O. V. Tsymbal, N. N. Ponomarenko, K. O. Egiazarian, J. T. Astola // *Remote Sensing: in Image and Signal Processing for Remote Sensing IX*. – Barcelona, 2003. – Vol. 5238. – P. 120 – 131.

13. Yoshida, Y. Classification of rotated and scaled textured images using invariants based on spectral moments [Text] / Y. Yoshida, Y. Wu // *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*. – 1998. – Vol. 81, № 8. – P. 1661 – 1666.

14. Three-state Locally Adaptive Texture Preserving Filter for Radar and Optical Image Processing [Text] / O. V. Tsymbal, V. V. Lukin, N. N. Ponomarenko, A. A. Zelensky, K. O. Egiazarian, J. T. Astola // *EURASIP Journal on Applied Signal Processing*. – 2005. – No 8. – P. 1185 – 1204.

15. Adaptive texture-preserving filtering of multi-temporal ERS-1 SAR images [Text] / B. Aiuzzi, L. Alparone, S. Baronti, R. Carla // *Remote Sensing: in proc.*

IEEE International Geoscience and Remote Sensing Symposium. – 1997. – Vol. 4. – P. 2066 – 2068.

16. Perry, S. W. *Adaptive Image Processing: A Computational Intelligence Perspective [Text]* / S. W. Perry, H. S. Wong, L. Guan // CRC Press. – 2002. – Vol. 3. – P. 233 – 238.

17. Rubel, A. *Efficiency of DCT-based denoising techniques applied to texture images [Text]* / A. Rubel, V. Lukin, O. Pogrebniak // *Remote Sensing: proceedings of MCP. – Cancun, 2014. – Vol. 5 – P. 111 – 120.*

18. Larnier, S. *Edge detection and image restoration with anisotropic topological gradient [Text]* / S. Larnier, J. Fehrenbach // *Remote Sensing: proceedings of ICASSP. – 2010 – Vol. 7. – P. 1362 – 1365.*

19. Gilboa, G. *Variational Denoising of Partly-Textured Images by Spatially Varying Constraints [Text]* / G. Gilboa, N. Sochen, Y. Zeevi // *IEEE Transactions on Image Processing. – 2006. – Vol. 15, No. 8. – P. 2281 – 2289.*

20. *Texture Enhanced Image Denoising via Gradient Histogram Preservation [Text]* / W. Zuo, L. Zhang, C. Song, D. Zhang // *Remote Sensing: proceedings of*

*CVP. – Portland 2013, – Vol. 6. – P. 1203 – 1210.*

21. Chatterjee, P. *Is Denoising Dead? [Text]* / P. Chatterjee, P. Milanfar // *IEEE Trans. Image Processing. – 2010. – Vol. 19, No. 4. – P. 895 – 911.*

22. *Image denoising by sparse 3D transform-domain collaborative filtering [Text]* / K. Dabov, A. Foi, V. Katkovnik, K. Egiazarian // *IEEE Transactions on Image Processing. – 2007. – Vol. 16, No. 8. – P. 2080 – 2095.*

23. *Image filtering based on discrete cosine transform [Text]* / V. Lukin, R. Oktem, N. Ponomarenko, K. Egiazarian // *Telecommunications and Radio Engineering. – 2007. – Vol. 66, No. 18. – P. 1685 – 1701.*

24. Scholkopf, B. *Learning with Kernels [Text]* / B. Scholkopf, A. Smola // MIT Press. – Cambridge, 2002. – Vol.3. – P. 113 – 123.

25. Xindong, W. *Top 10 algorithms in data mining [Text]* / W. Xindong // *Knowledge and Information Systems. – 2008. – Vol. 14, № 1. – P. 1 – 37.*

26. Fawcett, T. *An introduction to ROC Analysis [Text]* / T. Fawcett // *Pattern Recognition Letters. – 2005. – Vol. 27, No. 8. – P. 861 – 874.*

Поступила в редакцію 30.04.2015, рассмотрена на редколегии 18.06.2015

## ВИЯВЛЕННЯ ТЕКСТУРНИХ ДІЛЯНОК SVM- КЛАСИФІКАТОРОМ ПРИ НАЯВНОСТІ ЗАВАД

*С. С. Кривенко, А. В. Науменко, В. В. Лукін*

Розглянуто можливість застосування SVM-класифікатора для виявлення текстурних ділянок на зображеннях, на яких присутній досить інтенсивний адитивний шум. Показано, що ефективність такого класифікатора залежить від кількості вхідних ознак та розміру блоку, в яких ці ознаки обчислюються. Також продемонстровано застосовність навченого класифікатора для обробки зображень з різними текстурами і при різному рівні завад. Показано, що для чотирьох повністю текстурних тестових зображень досягається рівень чутливості класифікатора на рівні 0,85-0,95.

**Ключові слова:** текстура, виявлення, зображення, перешкоди, навчання.

## SVM-BASED NOISY IMAGE TEXTURE DETECTION

*S. S. Krivenko, A. V. Naumenko, V. V. Lukin*

The possibility of using SVM-classifier to detect texture regions on the images with intensive additive noise is considered. It is shown that the efficiency of the classifier depends on a number of input parameters and the size of the block in which these parameters are calculated. Also the applicability of the trained classifier for processing images with different textures and with different noise levels is demonstrated. It is shown that for four full texture test images the level of sensitivity of the classifier at 0.85-0.95 is achieved.

**Key words:** texture, detection, image, noise, machine learning.

**Кривенко Сергей Станиславович** – канд. техн. наук, с.н.с. каф. «Приема, передачи и обработки сигналов», Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», г. Харьков, Украина, e-mail: krivenko.sergiy@gmail.com.

**Науменко Алексей Васильевич** – аспирант каф. «Приема, передачи и обработки сигналов», Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», г. Харьков, Украина, e-mail: phist@mail.ru.

**Лукін Владимир Васильевич** – д-р техн. наук, проф., проф. каф. «Приема, передачи и обработки сигналов», Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», г. Харьков, Украина, e-mail: lukin@ai.kharkov.com.