

УДК 621.3:681.34

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

*Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», Украина*

## МОДИФИКАЦИЯ ОБНАРУЖИТЕЛЯ ТЕКСТУР С ПРИМЕНЕНИЕМ АГРЕГАЦИИ ВХОДНЫХ ПАРАМЕТРОВ

*Обоснована актуальность задачи обнаружения текстурных участков на изображениях. Предложена модификация метода обнаружения текстурных участков с помощью SVM-классификатора для изображений, на которых присутствует достаточно интенсивный аддитивный белый гауссов шум, при помощи агрегации входных параметров. Описана модифицированная процедура обучения классификатора. Приведены используемые критерии эффективности обработки. Для тестовых данных продемонстрированы эффективность разработанного подхода и повышение производительности классификатора при его применении.*

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

### Введение

Обработка изображений является одним из самых быстро развивающихся направлений исследований. Бурное развитие цифровых технологий, различных мультимедиа приложений и социальных сетей ведет к возрастающим требованиям к процедурам обработки и к поиску новых решений. В частности, ряд проблем в области распознавания образов, фильтрации и сегментации изображений связан со специфической задачей обнаружения и обработки текстурных участков [1, 2]. Например, часто желательно обнаружить текстурные фрагменты или участки, для которых есть либо эталон, либо набор текстурных признаков [3, 4].

Одновременно есть приложения, когда необходимо обнаружить и локализовать текстурные участки при отсутствии априорных сведений о характеристиках текстур [4, 5]. Подобные задачи часто приходится решать тогда, когда возникает необходимость оценить свойства текстуры, чтобы затем использовать их при классификации и распознавании объектов [6, 7].

Одна из основных трудностей, возникающих при применении указанных выше видов обработки и анализа, состоит в том, что исходные изображения могут быть искажены помехами (аддитивными, сигнально-зависимыми или мультипликативными в зависимости от типа изображений или условий, в которых они были получены [8-10]). Присутствие помех затрудняет обнаружение текстурных участков [11] и оценивание текстурных признаков, снижает визуальное качество изображений [12]. В связи с этим иногда применяют предварительную фильтрацию изображений с целью подавления помех. Тем

не менее, даже применение наилучших фильтров не приводят к заметному подавлению помех на текстурных участках [13-16]. Поэтому нередко целесообразно вообще не подвергать такие участки фильтрации, поскольку обработанные фильтром текстурные участки могут выглядеть «смазанными» или частично терять полезную информацию.

Таким образом, специфика решаемой нами задачи обнаружения текстур состоит в том, что нужно обнаруживать искаженные шумом текстурные участки с разными свойствами, не имея априорной информации о текстурных признаках для них.

Ранее нами были предложены методы обнаружения текстурных участков на основе искусственной нейронной сети [17] и машины опорных векторов [18]. Методы основывались на совместном анализе нескольких локальных параметров, чувствительных к текстурам. При этом каждый их параметров «оценивает» текстурные неоднородности с различных точек зрения, а классификатор выступает объединяющей системой. Обработка производилась в скользящем окне, и результат обнаружения присваивался значению центрального пикселя скользящего окна.

Поскольку текстуре принадлежат большинство пикселей, соседних с центральным пикселем скользящего окна, то можно предположить, что агрегация локальных параметров для нескольких соседних положений скользящего окна может улучшить результаты обнаружения (классификации пикселей на «текстура – не текстура»).

Цель статьи – исследовать эффективность классификаторов, основанных на агрегации параметров в соседних скользящих окнах.

## Свойства элементарных детекторов

Как отмечено выше, классификация данных для каждого положения скользящего окна обычно выполняется попиксельно, то есть решение о принадлежности рассматриваемого пикселя классу «Текстура» или «Не текстура» принимается на основе применения заранее обученного классификатора к набору входных признаков, рассчитанных для скользящего окна, центр которого совпадает с данным пикселем. Размер скользящего окна может быть разным.

Для того чтобы классификатор работал эффективно, входные признаки должны быть подобраны таким образом, чтобы «качественно описывать» классы [13]. В наших последних исследованиях [17] было показано, что наиболее эффективными, в случае обработки изображений систем дистанционного зондирования Земли, являются следующие локальные 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 неоднородностям и имеет значительно большие значения в скользящих окнах, попавших на границу или текстуру, чем для окон, расположенных на однородных участках.

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 и используемого размера скользящего окна. В наших последующих опытах для окна 5x5 пикселей эти значения были установлены равными 23 и 3 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), основанный на следующем принципе. В скользящем окне вычисляется двумерное ДКП. После этого рассчитывается количество коэффициентов ДКП, превысивших порог, который в рассматриваемых опытах был выбран равным  $2\sigma_{add}$ . Данный параметр (может быть нормирован на число пикселей в блоке) работает в спектральной области и учитывает тот момент, что для текстур обычно характерно присутствие достаточного количества явно выраженных пространственных спектральных компонент.

Рассматриваемые локальные параметры выбраны и применены, исходя из следующих соображений:

- различные локальные параметры проявляют себя разным способом для различных типов участков;

- используемые параметры базируются на нескольких различных принципах обнаружения неоднородностей, что позволяет классификатору быть более универсальным по отношению к свойствам обрабатываемых данных и устойчивым к помехам.

## Принцип агрегации локальных параметров

В предыдущих исследованиях для каждого из входных параметров классификатора (ОЛД, КР и ДКП) формировалась отдельная бинарная карта, рассчитанная для окон размера 5x5, на искаженных изображениях. Эти карты использовались для получения результата классификации для одного пикселя, описывающего его принадлежность к одному из определяемых классов (в данном случае «текстура» или «не текстура»).

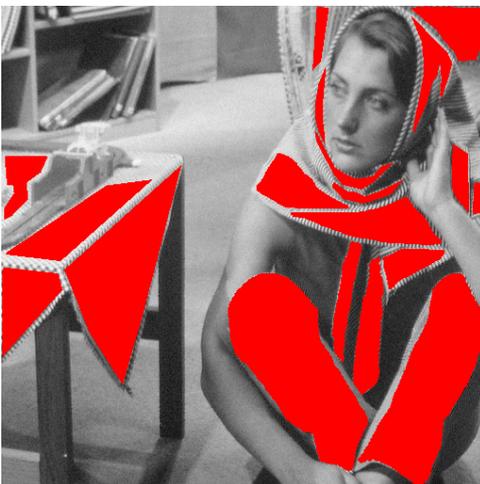
Под агрегацией нами ниже понимается следующая процедура. В исходном изображении для данной точки сопоставляются точки с аналогичными координатами на трех бинарных картах, соответствующих свойствам ОЛД, КР и ДКП. Каждая из точек на бинарной карте является центром квадратного окна агрегации (его размер может быть 1x1, 3x3, 5x5, 7x7 пикселей). Вектор входных свойств представляет собой совокупность трех окон (по одному для каждого из свойств) и имеет вид одномерного вектора, в котором последовательно представлены элементы трех окон. Данный вектор будет иметь размер 27 элементов для окна агрегации 3x3 и 75 элементов для окна агрегации 5x5. 1x1 в данном случае означает отсутствие агрегации и данные ре-

зультаты приводятся для сравнения. Таким образом, на вход классификатора поступают не только признаки данной точки, но и свойства соседних точек.

В качестве классификатора была использована машина опорных векторов (SVM-support vector machine). Для обучения было использовано известное черно-белое тестовое изображение *Varbaga*. Изображение было искусственно зашумлено аддитивным гауссовым шумом, имеющим среднеквадратическое отклонение (СКО), равное 5. Для представления пикселей, принадлежащих классам «текстура» и «не текстура», в ходе обучения использовалась цветовая маска, размеченная предварительно вручную, как описано в [5].



а



б

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

Для обучения и проверки были случайным образом выбраны 3000 пикселей, относящихся к текстуре и 3000 пикселей, относящихся к нетекстурным участкам. Затем этот массив данных

был разделен на обучающую выборку и 2 набора тестовых данных в пропорции 70/15/15.

Обучающая выборка разбивалась на пять частей: четыре для построения модели и одна для ее проверки. Процедура проверки модели была повторена пять раз.

В качестве критерия оптимизации был использован коэффициент сбалансированной ошибки, позволяющей работать с выборками, имеющими различный объем для различных классов (BER):

$$BER = 0,5 \left( \frac{NE_p}{NP} + \frac{NE_n}{NN} \right), \quad (3)$$

где  $NE_p$  – количество ложноположительных срабатываний классификатора,  $NP$  – общее количество элементов, принадлежащих одному из классов,  $NE_n$  – количество ложноотрицательных срабатываний,  $NN$  – общее количество элементов, принадлежащих второму классу.

В результате процедуры проверки было получено пять моделей, среди которых была выбрана одна, имеющая наименьший BER. Данная модель была использована для обучения и затем классификатор был верифицирован на двух тестовых выборках, определенных ранее. После этого были определены параметры чувствительности и специфичности классификатора. Для проверки данных параметров отдельно были использованы два специальных тестовых изображения: одно из них представляет собой изображения коры дерева и соответствует полностью текстурному изображению (*2.bmp*), второе – полностью однородное изображение, без текстур (*flat.bmp*).

### Результаты классификации

Для любого классификатора важно определить его производительность при работе с данными, которые не были задействованы при его обучении. В таблицах 1 и 2 приведены результаты вышеописанного эксперимента. В них содержатся, в частности, результаты работы обученного классификатора на обучающей выборке. Тест1 и Тест2 – результаты классификации на двух тестовых наборах соответственно. TPR (truepositiverate) – чувствительность классификатора. Этот параметр характеризует процент правильно детектированных пикселей текстурных участков. SPC (specificity) – специфичность классификатора. Данный параметр соответствует проценту правильно распознанных пикселей однородных участков. Оба параметра изменяются от 0 до 1, где 1 соответствует идеальному значению.

Анализ результатов показывает, что наилучшие показатели чувствительности и специфичности

классификатора получены при размере окна агрегации, равного 5x5 пикселей, и составляют 0,98, что подтверждается результатами обработки тестовых выборок: чувствительность для первой и второй тестовой выборки 0,93 и 0,89 соответственно; специфичность – 0,88 и 0,91.

Таблица 1

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

| Размер окна | Barbara.bmp |          |           |           |           |           |
|-------------|-------------|----------|-----------|-----------|-----------|-----------|
|             | Обуч TPR    | Обуч SPC | Тест1 TPR | Тест1 SPC | Тест2 TPR | Тест2 SPC |
| 1           | 0,88        | 0,80     | 0,88      | 0,81      | 0,87      | 0,78      |
| 3           | 0,96        | 0,95     | 0,93      | 0,80      | 0,93      | 0,78      |
| 5           | 0,98        | 0,98     | 0,93      | 0,88      | 0,89      | 0,91      |
| 7           | 0,92        | 0,92     | 0,91      | 0,88      | 0,91      | 0,90      |

Таблица 2

Анализ эффективности классификаторов для изображений 2.bmp и Flat.bmp, искаженных шумом с СКО=5

| Размер окна | TPR (2.bmp) | SPC (Flat.bmp) |
|-------------|-------------|----------------|
| 1           | 0,89        | 1,00           |
| 3           | 0,96        | 0,99           |
| 5           | 0,96        | 0,99           |
| 7           | 0,95        | 0,99           |

Исходные изображения и бинарные карты результатов классификации представлены на рис. 2 и 3. Темные области соответствуют нетекстурным участкам, белые - обнаруженной текстуре.

Анализ представленных карт говорит о следующем. Классификатор, работающий в окне агре-

гации размером 5, хорошо обнаруживает малоразмерные текстуры, в то время как тот, что работает в окне агрегации размером 7, оказывается слабо чувствительным к таким участкам.

Чувствительность классификатора на полно текстурном изображении (рисунок 3) составляет 0,96. Ввиду отсутствия предварительно подготовленной карты текстур для изображений предполагалось, что процент текстур составляет 100%. Поэтому этот показатель определялся как отношение корректно классифицированных пикселей к общему количеству пикселей (размер изображений – 512x512 пикселей). Специфичность на полностью однородном изображении равна 0,99 (рисунок 4).

## Выводы

Предложен метод агрегации локальных параметров, используемых в качестве входных данных для классификатора текстурных участков. При применении данного метода в скользящем окне удалось существенно повысить как чувствительность (с 0,83 до 0,93), так и специфичность (с 0,85 до 0,91) классификатора, по сравнению с предыдущими исследованиями, где агрегация не применялась. При этом время обучения и обработки изображений не подверглось изменениям.

Одним из дальнейших направлений исследований может быть применение агрегации для других размеров окон. Также следует рассмотреть несколько моделей помех, присутствующих на изображении. Недостатком является некоторое замедление алгоритма распознавания текстур.



а



б

Рис. 2. Бинарные карты для изображений Barbara, СКО=5: а – размер окна 5x5, б – размер окна 7x7

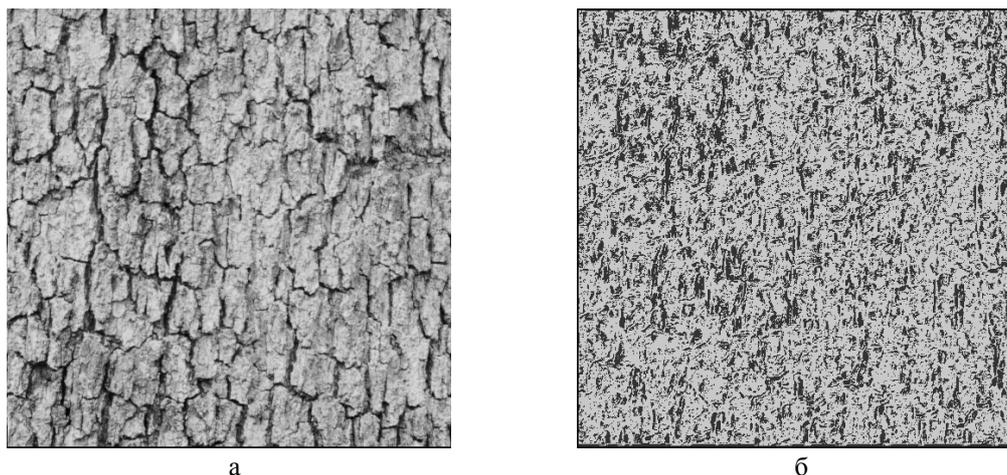


Рис. 3. Изображение 2.bmp: а - полностью текстурное тестовое изображение; б – бинарная карта для окна размером 5

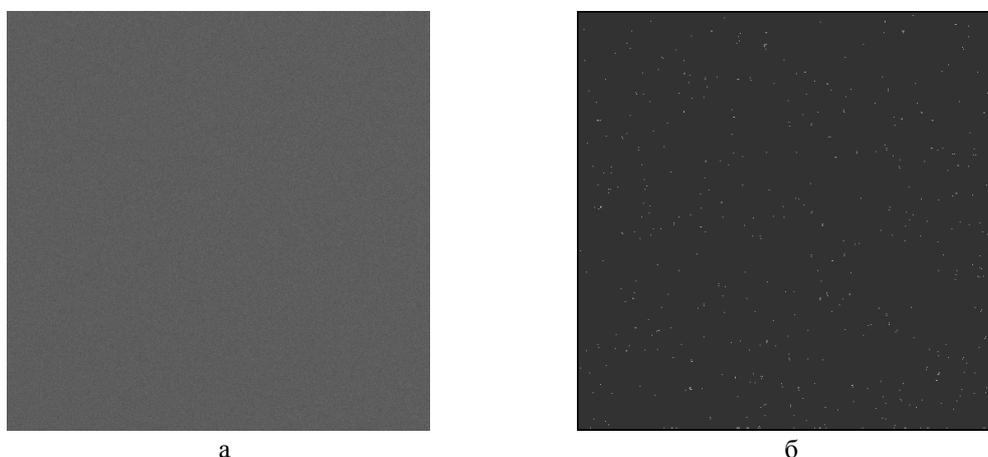


Рис. 4. Изображение flat.bmp: а - полностью однородное тестовое изображение; б – бинарная карта для окна размером 5

### 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. 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.

5. 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.

6. *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.

7. Wang, Xiang-Yang. *Content-based image retrieval by integrating color and texture features [Text]* / Xiang-Yang Wang, Bei-Bei Zhang, Hong-Ying Yang // *Multimed Tools Appl.* – 2014. – Vol. 68. – P. 545–569.

8. Крылов, В. Н. *Частотно-детекторный метод текстурной сегментации изображений [Текст]* / В. Н. Крылов, М. В. Полякова // *Информационно-измерительные системы.* - 2005. - № 2. - С. 3 - 8.

9. *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.

10. Popescu, Anca A. *Contextual Descriptors for Scene Classes in Very High Resolution SAR Images [Text]* / Anca A. Popescu, Inge Gavut // *IEEE Geoscience and remote sensing letters.* – 2012. – Vol. 9. – P. 80-84.

11. 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.

12. 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.

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. Rubel, A. Efficiency of DCT-based denoising techniques applied to texture images [Text] / A. Rubel, V. Lukin, O. Pogrebniak // *Proceedings of MCPFR*. - Cancun, 2014. - Vol. 5 - P. 111 - 120.

15. 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.

16. Adaptive texture-preserving filtering of multitemporal ERS-1 SAR images [Text] / B. Aiazzi, L. Alparone, S. Baronti, R. Carla // *Remote Sensing: in Proc. IEEE International Geoscience and Remote Sensing Symposium*. - 1997. - Vol. 4. - P. 2066 - 2068.

17. Обнаружение текстурных участков на изображениях при наличии помех классификатором на основе нейросети [Текст] / А. В. Науменко, С. С. Кривенко, М. С. Зряхов, В. В. Лукин // *Радіоелектронні і комп'ютерні системи*. - 2016. - № 1. - С. 35-44.

18. Texture Detection in Noisy Images by Combining Several Local Parameters [Text] / A. Naumenko, S. Krivenko, N. Ponomarenko, V. Lukin, A. Zelensky // *Proceedings of the Conference Problems of Infocommunications. Science and Technology. Kharkov, Ukraine, October 2015*. - P. 230-233.

## References

1. Pratt, W. K. Digital Image Processing. Fourth Edition. N. Y., Wiley-Interscience Publ., USA, 2007. 1429 p.

2. Haralick, R. M. Textural features for image classification. *IEEE Trans. Syst., Man, Cybern.*, vol. 3, no. 6, 1973, pp. 610-621.

3. Malik, J., Belongie, S., Leung, T., Shi, J. Contour and texture analysis for image segmentation. *IJCV*, vol. 7, 2001, pp. 27-31.

4. Micusik, B., Hanbury, A. Supervised texture detection in images. *Proceedings of 11-th International Conference on Computer Analysis of Images and Pat-*

*terns*, Versailles, France, Sept. 2005, pp. 441-448.

5. Bevz, E. G. Algoritmy segmentacii dlja zadach teksturnogo analiza s primeneniem metoda sintaksicheskogo opisaniya tekstur [Segmentation algorithms for texture analysis tasks using the syntax description of the method of textures]. *Doklady Belorusskogo gosudarstvennogo universiteta informatiki i radioelektroniki*, Belorussia, 2011, no. 8 (62), pp. 9-13.

6. Lukin, V. V., Tsymbal, O. V., Ponomarenko, N. N., Egiazarian, K.O. and Astola, J. T. Image processing with texture feature preservation by three-state locally adaptive filter. *Image and Signal Processing for Remote Sensing IX*, Barcelona, Spain, vol. 5238 of SPIE Proceedings, September 2003, pp. 120-131.

7. Wang, Xiang-Yang., Zhang, Bei-Bei., Yang, Hong-Ying. Content-based image retrieval by integrating color and texture features, *Multimed Tools Appl*, vol. 68, 2014, pp. 545-569.

8. Krylov, V. N., Poljakova, M.V. Chastotno-detektornyj metod teksturnoj segmentacii izobrazhenij [Frequency detection method of texture image segmentation]. *AAJeKS Informacionno-izmeritel'nye sistemy*, 2005, no. 2(16), pp. 40-46.

9. Hayman, E., Caputo, B., Fritz, M., Eklundh, J. On the significance of real-world conditions for material classification, *Computer Vision: proc. 8th European Conf. on Computer Vision*. Prague, vol. 4, 2004, pp. 253-266.

10. Popescu, Anca A., Gavath, Inge. Contextual Descriptors for Scene Classes in Very High Resolution SAR Images, *IEEE Geoscience and remote sensing letters*. vol. 9, 2012, pp. 80-84.

11. Partio, M. Applying texture and color features to natural image retrieval. *Proc. Finnish Signal Processing Symposium (FINSIG '03)*, Tampere, Finland, May 2003, pp. 199-203.

12. Nunes, J. C., Niang, O., Bouaoune, Y., Delechelle, E., Bunel, Ph. Texture analysis based on the bidimensional empirical mode decomposition with gray-level co-occurrence models. *Proc. 7th International Symposium on Signal Processing and Its Applications*, Paris, France, vol. 2, July 2003, pp. 633-635.

13. Yoshida, Y., Wu, Y. Classification of rotated and scaled textured images using invariants based on spectral moments. *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 81, 1998, pp. 1661-1666.

14. Rubel, A., Lukin, V., Pogrebniak, O. Efficiency of DCT-based denoising techniques applied to texture images. *Proceedings of MCPFR*, Cancun, Mexico, LNCS 8495, June 2014, pp. 111-120.

15. Tsymbal, O. V., Lukin, V. V., Ponomarenko, N. N., Zelensky, A. A., Egiazarian, K. O., Astola, J. T. Three-state Locally Adaptive Texture Preserving Filter for Radar and Optical Image Processing. *EURASIP Journal on Applied Signal Processing*, no. 8, May 2005, pp. 1185-1204.

16. Aiazzi, B., Alparone, L., Baronti, S., Carla, R. Adaptive texture-preserving filtering of multitemporal ERS-1 SAR images. *Proc. IEEE International Geo-*

*science and Remote Sensing Symposium (IGARSS '97)*, Singapore, vol. 4, August 1997, pp. 2066–2068.

17. Naumenko, A. V., Krivenko, S. S., Zrjakhov, M. S., Lukin, V. V. Obnaruzhenie teksturnykh uchastkov na izobrazheniyah pri nalichii pomех klassifikatorom na osnovе nejroseti, *Radioelektronni i komp'yuterni sistemi*, vol. 1, 2016, pp. 35–44.

18. Naumenko, A., Krivenko, S., Ponomarenko, N., Lukin, V., Zelensky, A. Texture Detection in Noisy Images by Combining Several Local Parameters, *Proceedings of the Conference Problems of Infocommunications. Science and Technology*, Kharkov, Ukraine, October 2015, pp. 230-233.

*Поступила в редакцію 15.01.2017, рассмотрена на редколлегии 16.02.2017*

### МОДИФІКАЦІЯ МЕТОДУ ВИЯВЛЕННЯ ТЕКСТУР З ВИКОРИСТАННЯМ АГРЕГАЦІЇ ВХІДНИХ ПАРАМЕТРІВ

*С. С. Кривенко, О. В. Науменко, М. С. Зряхов, В. В. Лукін*

Обґрунтовано актуальність виявлення текстурних ділянок на зображеннях. Запропоновано модифікацію методу виявлення текстурних ділянок за допомогою SVM-класифікатора для зображень, на яких присутній досить інтенсивний адитивний білий гаусів шум, за допомогою агрегації вхідних параметрів. Описано модифіковану процедуру навчання класифікатора. Наведено критерії ефективності обробки, що використовуються в процесі аналізу. Для тестових даних продемонстровано ефективність розробленого підходу і підвищення ефективності класифікатора при його застосуванні.

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

### MODIFICATION OF TEXTURE DETECTION METHOD USING FEATURE AGREGATING

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

The importance of texture area detection in images is motivated. A modification of the method of texture area detection using SVM-classifier for images corrupted by rather intensive additive white Gaussian noise by aggregation of input parameters is proposed. A modified procedure of classifier training is described. Criteria of processing efficiency used in analysis are given. For test data, the effectiveness of the developed approach and improvement of classifier performance are demonstrated.

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

**Кривенко Сергей Станиславович** – канд. техн. наук, ст. науч. сотр. каф. «Приема, передачи и обработки сигналов», Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», 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», Харьков, Украина, e-mail: phist@mail.ru.

**Зряхов Михаил Сергеевич** – канд. техн. наук, доцент каф. «Приема, передачи и обработки сигналов», Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», Харьков, Украина, e-mail: zriakhov.ms@gmail.com.

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

**Sergey S. Krivenko** – Candidate of Technical Sciences, Senior Researcher of Dept of "Transmitters, Receivers and Signal Processing", National Aerospace University named after N. E. Zhukovsky "KhAI", Kharkiv, Ukraine, e-mail: krivenko.sergiy@gmail.com.

**Alexey V. Naumenko** – postgraduate student of Dept of "Transmitters, Receivers and Signal Processing", National Aerospace University named after N. E. Zhukovsky "KhAI", Kharkiv, Ukraine, e-mail: phist@mail.ru.

**Mikhail S. Zriakhov** - Candidate of Technical Sciences, Associate Professor of Dept of "Transmitters, Receivers and Signal Processing", National Aerospace University named after N. E. Zhukovsky "KhAI", Kharkiv, Ukraine, e-mail: zriakhov.ms@gmail.com.

**Vladimir V. Lukin** – Doctor of Technical Sciences, Professor, Head of Dept of "Transmitters, Receivers and Signal Processing", National Aerospace University named after N. E. Zhukovsky "KhAI", Kharkiv, Ukraine, e-mail: lukin@ai.kharkov.com.