

УДК 621.3:681.34

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

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

*Проанализирована возможность обнаружения текстурных участков на изображениях, искаженных аддитивным некоррелированным шумом, классификатором на основе обученной нейросети. Исследованы следующие наборы входных параметров (признаков): относительная локальная дисперсия, детектор Харриса, простой детектор текстур, детектор на основе дискретно-косинусного преобразования. Показано, что характеристики обнаружения зависят от количества входных признаков и от того, какие именно входные параметры используются. Обсуждены вопросы обучения нейросети и применения обученного классификатора для обработки изображений с различными текстурами.*

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

**Введение**

Изображения в настоящее время являются одними из важных источников извлечения и представления информации [1, 2]. Важным элементом изображений являются текстуры [3, 4], признаки которых используют в различных приложениях – при поиске изображений по подобию в базах большого размера [5], при решении задачи сегментации изображений [6, 7], для классификации материалов, используя данные дистанционного зондирования (ДЗ) [8], и т.д.

Очевидно, что до определения текстурных признаков необходимо сначала обнаружить текстурные участки. При этом возможны различные постановки задачи. Например, может быть необходимо обнаружить только такие текстурные участки, для которых наблюдается заданный набор текстурных признаков [9, 10]. Для других приложений нужно обнаружить и оконтурить любые текстурные участки, то есть решить задачу обнаружения [11, 12] при отсутствии априорных сведений о текстурных признаках [13, 14]. В частности, такая задача возникает при локально-адаптивной фильтрации [11, 12] изображений (приоритет требований при обработке текстурных участков отличается от приоритета требований [14] к фильтрам при обработке однородных участков) [15-17].

Специфика постановки этой задачи заключается в том, что исходные (подлежащие обработке) изображения искажены помехами [12, 14], причем эти помехи могут быть разного типа (аддитивные, сигнально-зависимые, мультипликативные) и интенсивности [15-17]). Многие алгоритмы сегментации и обнаружения текстур не учитывают эту особенность. В то же время помехи, безусловно, осложняют обнаружение текстурных участков [12] и снижают визуальное качество изображений [18].

При этом применение даже наилучших из современных фильтров не гарантирует эффективное подавление помех и улучшение визуального качества [19-21]. Даже один из лучших на данный момент фильтр ВМ3D [22] не всегда справляется с поставленными задачами [14, 17]. К счастью, на данный момент есть способ предсказания эффективности фильтрации [17], который может способствовать принятию решения, стоит ли применять фильтрацию для данного вида текстуры при известном уровне и типе помех [17]. Тогда задача состоит в обнаружении текстурных участков в предположении, что тип и уровень помех известен. Поскольку (методы и успешные примеры решения задачи автоматического определения типа и оценки параметров помех известны [23, 24]).

Один из возможных вариантов решения задачи обнаружения текстурных участков на изображениях, искаженных аддитивными помехами, рассмотрен в нашей работе [25], используя SVM-классификатор [26]. Основная идея состояла в том, чтобы «объединить» таким обучаемым классификатором значения на выходе элементарных детекторов (показателей локальной активности) с целью более надежно обнаружить текстурные участки.

Естественно, что при таком подходе к решению задачи итоговый эффект зависит от многих факторов – используемого классификатора, методики его обучения, входных параметров, уровня помех. Поэтому в данной статье внимание уделено двум аспектам – анализу возможности использования другого популярного средства объединения нескольких разнородных входных параметров (классификатора) – нейронной сети (НС) [27] – и исследованию влияния выбора количества и состава входных признаков. *Цель статьи* – разработать классификатор «текстура – не текстура» на основе НС и проанализировать его свойства.

## Используемые локальные параметры и их свойства

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 7x7 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.

Набор используемых параметров, рассчитываемых для  $ij$ -го положения окна (блока), определен эмпирически и включает следующие параметры:

1. 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 неоднородным участкам и имеет существенно большие значения в скользящем окне, попавшем на границу или текстуру, чем в окне, попавшем на однородный участок.

2. Нормированный квазиразмах (КР) (для случая присутствия аддитивной помехи)

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

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. Ниже эти значения были установлены равными, 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 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 также нормирован на число пикселей или, что эквивалентно, число ДКП-коэффициентов в блоке  $N$ ) работает в спектральной области и учитывает тот момент, что для текстур обычно характерно присутствие достаточного количества относительно явно выраженных пространственных спектральных компонент. Выбор значений порогов или способов нормировки для перечисленных выше 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.

4. Простой детектор текстур (ДТ) [28]. Основной принцип детектирования - определение «плотности» текстуры, путем вычисления пиковых значений интенсивности пикселей и отнесения количества этих пиковых значений к общему числу пикселей в окне. Данный параметр не учитывает статистику помех на изображении и является, по сути, полностью геометрическим параметром.

5. Детектор Харриса (ДХ) [29]. Еще один геометрический параметр, результирующее значение которого для скользящего окна зависит от отношения средних значений элементов, находящихся в различных частях окна.

В отличие от более ранней работы [25] ниже рассмотрены возможности использования при обнаружении текстурных участков двух новых локальных параметров - ДТ и ДХ. ДХ ранее хорошо проявил себя при обнаружении границ [30] и его привлечение предположительно может различить наличие в окне границы или текстуры. ДТ использовался в [28] как раз для обнаружения текстурных участ-

ков, однак при відсутності шумів.

Підхід, що передбачає об'єднання декількох різних детекторів, виникає з наступних висновків. Параметри, що розділяють, зазвичай не здатні ефективно «розділити» розглядавані класи («текстура» і «не текстура», в даному випадку). Для демонстрації цього наведемо декілька прикладів гистограм значень на виході трьох елементарних детекторів, отриманих окремо на текстурних і нетекстурних ділянках зображень (рис. 1-3).

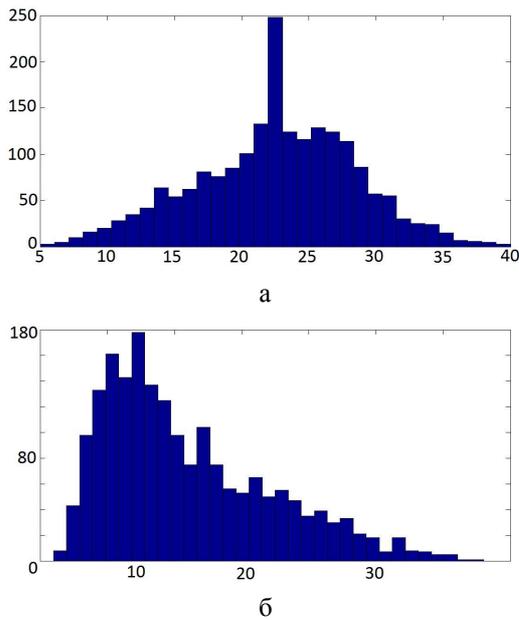


Рис. 1. Гистограми значень елементарного детектора на основі ДКП: а – не текстури; б – текстури

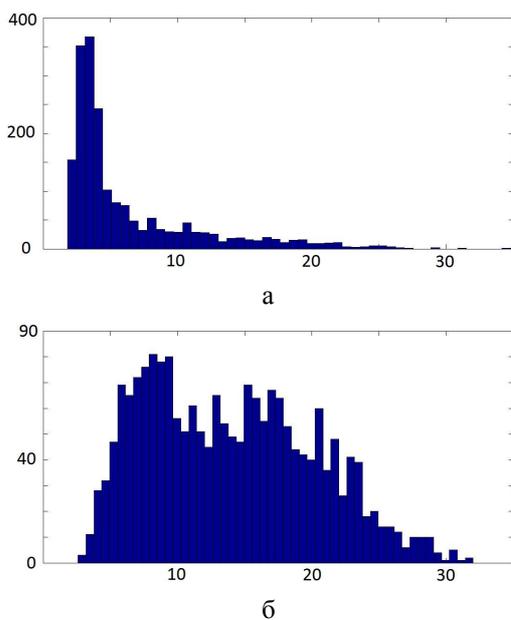


Рис. 2. Гистограми значень елементарного детектора на основі КР: а – не текстури; б – текстури

На показаних гистограмах добре видно їх особливості (різниця), що характеризують здат-

ності детектора до розрізнення розглядаваних класів. Видно, що для детектора на основі ДКП спостерігається чітко виражене рознесення максимумів гистограм для текстур і нетекстур, що дозволяє непогано розділити дані класи. Для КР області найбільш ймовірних значень також «рознесені», а для ОЛД спостерігається трохи інша ситуація: ймовірні значення для класів суттєво перекриваються. Це означає, що даний детектор не занадто добре підходить для розрізнення розглядаваних класів, тому, скоріше за все, його слід виключити зі списку входних параметрів НС-класифікатора.

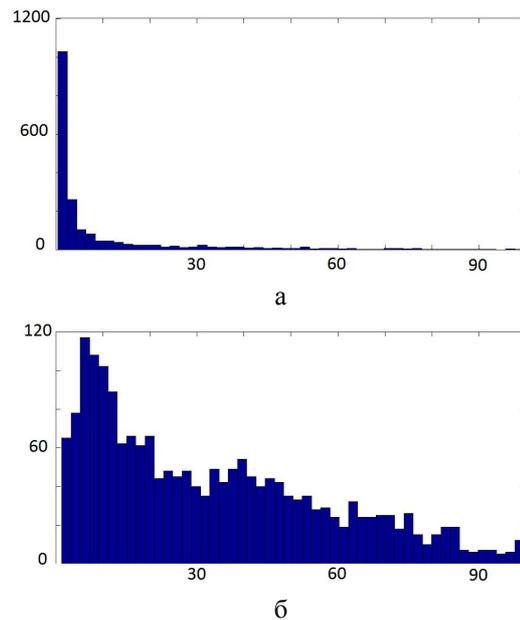


Рис. 3. Гистограми значень елементарного детектора на основі ОЛД: а – не текстури; б – текстури

Основна причина «пересічення» інтервалів значень вказаних вище параметрів для розглядаваних класів – подібність їх значень для текстурних ділянок і околиць меж і мало-розмірних об'єктів, віднесених до класу «нетекстура».

З урахуванням різного поведінки локальних параметрів для розглядаваних класів має сенс спробувати об'єднати декілька найбільш ефективних елементарних детекторів в передположенні, що результуюча система (класифікатор) буде мати більшу чутливість і специфічність.

З метою об'єднання рознорідних параметрів була використана нейронна мережа, що складається з 3х шарів. Кількість нейронів у входному шарі відповідає кількості входних параметрів, тобто було різно в кожному випадку (в статті розглядаються випадки від 2 до 4 входних параметрів). Кількість нейронів у прихованому шарі: на 2 більше, ніж у входному (згідно з емпіричними правилами навч-

ния нейронных сетей [27]). Выходной же слой содержит 2 нейрона, которые соответствуют распознаваемым классам.

Для обучения нейронной сети было использовано изображение Barbara (рис. 4а), искаженное аддитивным Гауссовым шумом с нулевым средним и среднеквадратическим отклонением (СКО), равным 5. Предварительно данное изображение было размечено в интерактивном режиме на области, соответствующие текстурным и нетекстурным участкам. Это позволило сформировать наборы центральных пикселей окон, соответствующих классам «Текстура» и «Нетекстура».

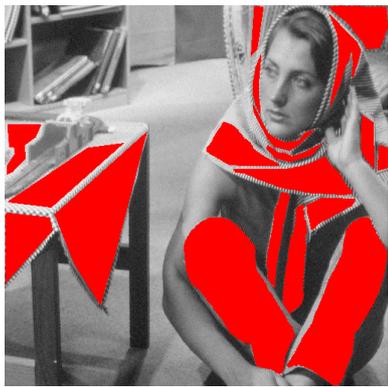


Рис. 4. Изображение Barbara: а – исходное; б – зашумленное с СКО=5 (красным помечены области текстур)

Из всего набора входных параметров были составлены все возможные комбинации из двух, трех и четырех параметров. Это сделано для того, чтобы экспериментально найти наиболее эффективные наборы, так как ранее было установлено [25], что некоторые параметры могут «мешать» друг другу, будучи использованными совместно в качестве входных параметров нейронной сети.

### Результаты обучения и классификации

Как уже отмечалось, изображение Barbara было предварительно вручную размечено (рис.4б). Крас-

ный цвет соответствовал текстурным участкам. Остальные участки считались нетекстурными. Размер обучающей выборки был равен 1000 наборов входных параметров, а размер двух тестовых выборок равен 500 элементов. Тестовые выборки не были задействованы в процессе обучения классификатора и использовались нами для оценки эффективности классификатора и его прогностических свойств.

Оценка эффективности различения двух классов проводилась с помощью параметра AUC [31], который хорошо зарекомендовал себя в предыдущих исследованиях [30]. Напомним, что данный параметр характеризует эффективность (чувствительность и специфичность) детектора единым числом, которое изменяется в пределах [0,1]. Чем выше эффективность детектора, тем ближе данный показатель к 1.

В первую очередь все подготовленные и обученные нейронные сети были протестированы на изображении Barbara. Некоторые результаты для трех входных параметров приведены в таблице 1.

Таблица 1  
Результаты проверки нейронных сетей на изображении Barbara

Входные параметры			AUC
ОЛД	КР	ДХ	0,431
ОЛД	КР	ДКП	0,835
ОЛД	КР	ДТ	0,813
ОЛД	ДХ	ДКП	0,696
ОЛД	ДХ	ДТ	0,841
ОЛД	ДКП	ДТ	0,732
КР	ДХ	ДКП	0,811
КР	ДХ	ДТ	0,822
КР	ДКП	ДТ	0,802
ДХ	ДКП	ДТ	0,641

Очевидно, что эффективности обнаружителей на основе обученных НС существенно отличаются. Есть варианты наборов входных параметров, которые явно уступают остальным по эффективности. Значение AUC для них лежит в пределах 0,43..0,696, но при этом есть и комбинации, обеспечивающие значения AUC выше 0,8.

В связи с этим оставим для дальнейшего исследования несколько вариантов классификатора на основе НС, которые обеспечивают примерно одинаковые результаты обнаружения текстурных участков на использованном тестовом изображении. При этом учитывается тот факт, что значения AUC могут быть в определенной степени обусловлены особенностями изображения, на котором проводилось обучение, и уровнем сгенерированных помех. Поэтому необходимо провести более тщательную верификацию и на ее основе сделать окончательные выводы.

Аналогично для комбинации из двух и четырех

входных параметров для дальнейшего анализа были оставлены только лучшие комбинации, которые при верификации на изображении Barbara обеспечивали значения AUC выше 0,8.

Для того, чтобы иметь возможность проверить эффективность применения обученной нейронной сети, были созданы дополнительные тестовые изображения, содержащие явно выраженные текстурные (слева) и однородные участки (справа, см. рис. 5). Текстуры на данных изображениях имеют различную степень зернистости, а также контрастности и регулярности.

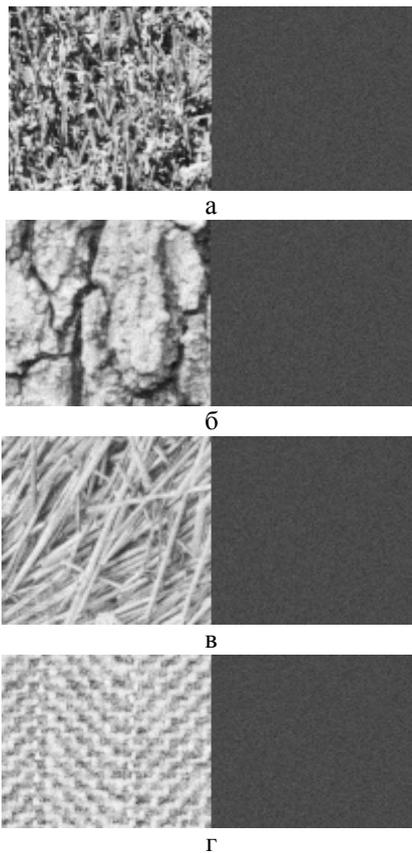


Рис. 5. Изображения, содержащие явно выраженные текстурные и однородные участки

Ниже приведены таблицы для проведения сравнительного анализа показателей для оставленных для анализа наилучших классификаторов на основе обученных НС. В таблицах приведены наборы параметров, которые являлись входными для нейронной сети и результаты оценки их эффективности для четырех тестовых изображений.

Анализируя результаты, представленные в таблицах, можно сделать следующие выводы. В качестве однозначных «лидеров» можно выделить две нейронные сети: с 4-мя входными параметрами (КР, ДХ, ДТ и ДКП) и с 3-мя входными параметрами (КР, ДХ и ДКП). Отметим, что в обоих наборах не присутствует ОЛД.

Таблица 2

Сравнительный анализ классификаторов для изображения «трава» (рис. 5а), искаженного шумом с СКО=5

Входные параметры				AUC
КР	ДХ	ПД	ДКП	0,993
ДХ	ПД			0,955
КР	ДХ	ДКП		0,990
КР	ДХ	ПД		0,623
ОЛД	ДХ	ПД		0,950
ОЛД	КР	ПД		0,761
ОЛД	КР	ДКП		0,763

Таблица 3

Сравнительный анализ классификаторов для изображения «кора» (рис. 5б), искаженного шумом с СКО=5

Входные параметры				AUC
КР	ДХ	ПД	ДКП	0,967
ДХ	ПД			0,908
КР	ДХ	ДКП		0,972
КР	ДХ	ПД		0,659
ОЛД	ДХ	ПД		0,409
ОЛД	КР	ПД		0,885
ОЛД	КР	ДКП		0,731

Таблица 4

Сравнительный анализ классификаторов для изображения «сено» (рис. 5в), искаженного шумом с СКО=5

Входные параметры				AUC
КР	ДХ	ПД	ДКП	0,988
ДХ	ПД			0,975
КР	ДХ	ДКП		0,981
КР	ДХ	ПД		0,864
ОЛД	ДХ	ПД		0,536
ОЛД	КР	ПД		0,912
ОЛД	КР	ДКП		0,897

Таблица 5

Сравнительный анализ классификаторов для изображения «ткань» (рис. 5г), искаженного шумом с СКО=5

Входные параметры				AUC
КР	ДХ	ПД	ДКП	0,981
ДХ	ПД			0,985
КР	ДХ	ДКП		0,975
КР	ДХ	ПД		0,921
ОЛД	ДХ	ПД		0,814
ОЛД	КР	ПД		0,944
ОЛД	КР	ДКП		0,929

Указанные два набора входных параметров обеспечивают очень хорошие результаты на всех четырех тестовых изображениях (рис. 5). Следует отметить, что эффективность абсолютно всех нейросетевых детекторов ниже при обработке изображения «Кора» (рис. 5,в). Это, вероятно, связано с тем, что данное изображение явно выделяется из остального набора характерным размером и структурой текстуры. Нейронные сети были обучены для существенно меньшего характерного размера текстуры. Однако, несмотря на это, эффективность наилучших нейронных сетей, остается достаточно высокой (значения AUC находятся на уровне 0,96 - 0,97 и выше).

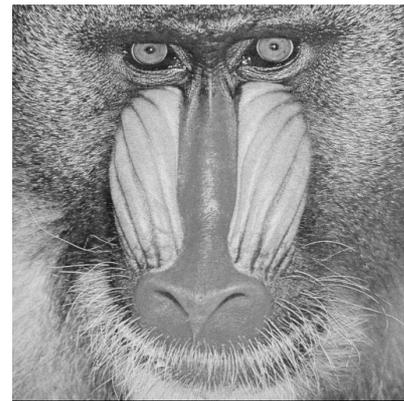
Кроме того, следует также обратить внимание на нейронную сеть, обученную лишь по двум параметрам – детектору Харриса и Простому детектору текстур. Данная нейронная сеть имеет высокую эффективность и лишь немного отстает от «лидеров». Она заслуживает внимания, так как требует меньше вычислительной мощности в виду того, что количество входных параметров меньше. Возможны практические ситуации, когда экономия вычислительной мощности оказывается критичным аспектом и эффективностью можно в определенной степени пожертвовать. В таких ситуациях следует использовать именно данную нейронную сеть.

Как видно, наиболее эффективными оказались нейронные сети, задействующие параметры, базирующиеся на введенных в рассмотрение геометрических признаках (ДХ, ДТ). Такая особенность является характерной для детектирования именно текстурных участков, так как для границ и малоразмерных объектов наилучшим образом проявили себя статистические параметры [25].

Как уже отмечалось, для любых классификаторов важно всесторонне проверить, как они работают для данных, для которых их обучение не проводилось. Ниже будут приведены карты текстурных участков только для трех наиболее эффективных детекторов, описанных выше. Представлены результаты работы классификаторов на изображении Baboon для шума с СКО=5 (рис. 6).

Данный случай представляет интерес, поскольку характеристики текстуры отличается от тех, на которых нейросеть была обучена. Кроме того, представлены результаты работы на изображении Baboon с другим уровнем шума: СКО=10 (рис. 7).

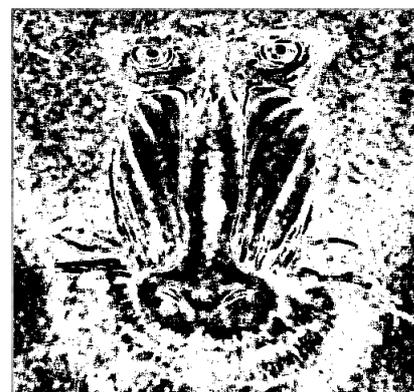
Анализ представленных на рис. 6 и 7 карт текстурных участков показывает, что параллельно с хорошим обнаружением текстур классификатор также частично реагирует на разнообразные неоднородности – границы, малоразмерные объекты и их окрестности. Это связано с тем фактом, что входные параметры являются также обнаружителями гра-



а



б



в



г

Рис. 6. Карты текстурных участков (Baboon, СКО=5): а – зашумленное изображение; б – 4 параметра; в – 3 параметра; г – 2 параметра

ниц [14]. При обробці зображень с СКО=10 (рис. 7) ефективність виявлення практично не падає, і текстурні частки виявлені достатньо хорошо ( $AUC=0,81..0,83$ ).



а



б



в

Рис. 7. Карты текстурных участков (Barbara, СКО=10): а – 4 параметра; б – 3 параметра; в – 2 параметра

Это позволяет считать, что разработанный обнаружитель (классификатор) достаточно устойчив к изменению уровня помех, что является положительным результатом. При обработке изображений с СКО=10 (рис. 7) эффективность обнаружения практически не падает, и текстурные участки обнаруже-

ны достаточно хорошо ( $AUC=0,81..0,83$ ). Это позволяет считать, что разработанный обнаружитель (классификатор) достаточно устойчив к изменению уровня помех, что является положительным результатом.

При обработке изображений с СКО=10 (рис. 7) эффективность обнаружения практически не падает, и текстурные участки обнаружены достаточно хорошо ( $AUC=0,81..0,83$ ). Это позволяет считать, что разработанный обнаружитель (классификатор) достаточно устойчив к изменению уровня помех, что является положительным результатом.

Вместе с тем, разработанный классификатор, будучи обученным для одного типа текстуры (Barbara), хорошо работает и для других текстур (см. результаты для тестового изображения Baboon).

## Выводы

В ходе проведенных опытов показано, что наилучший результат для классификации текстур на изображении с помощью нейронной сети обеспечивает использование четырех параметров в качестве входных данных: квазиразмаха, детектора Харриса, простого детектора текстур и детектора на основе ДКП. Сравнимые результаты показывает нейросеть на основе трех параметров: квазиразмаха, детектора Харриса и детектора на основе ДКП. Кроме того, нейронная сеть, обученная только по двум параметрам (детекторе Харриса и простом детекторе текстур) не слишком отстает по эффективности от вышеупомянутых, однако требует меньше вычислительной мощности. Поэтому, в случаях, когда первостепенное значение имеет простота обработки, следует применять именно этот подход.

Выявлено, что при большом характерном размере текстур (крупнозернистых текстур) эффективность детекторов несколько падает. В дальнейшем будет рассмотрена возможность исправить этот недостаток за счет обучения на нескольких вариантах текстуры, а также увеличении размера скользящего окна, который в настоящих опытах был равен  $7 \times 7$ .

## Литература

1. Pratt, W. K. *Digital Image Processing. Fourth Edition [Text]* / W. K. Pratt. – New York.: Wiley-Interscience. – USA. – 2007. – 1429 p.
2. Schowengerdt, R. *Remote Sensing: Models and Methods for Image Processing [Text]* / R. Schowengerdt. – Academic Press, 2006. – 560 p.
3. Haralick, R. *A pattern recognition approach to detection of complex edges [Text]* / R. Haralick, D. Dori // *Pattern Recognition. Letter.* – 1995. – No. 5. – P. 517–529.
4. Haralick, R. M., *Textural features for image classification [Text]* / R. M. Haralick, K. Shanmugam, I.

Dinstein // *IEEE Trans. Syst.* – 1973. – vol. 3, no. 6. – P. 610–621.

5. Applying texture and color features to natural image retrieval [Text] / M. Partio, E. Guldogan, O. Guldogan, and M. Gabbouj // in *Proc. Finnish Signal Processing Symposium (FINSIG '03)*. - Tampere, Finland, 2003. – P. 199–203.

6. Бевз, Е. Г. Алгоритмы сегментации для задач текстурного анализа с применением метода синтаксического описания текстур [Текст] / Е. Г. Бевз // Доклады БГУИР. – Беларусь, 2011. – № 8 (62). – С. 9-13.

7. Крылов, В. Н. Частотно-детекторный метод текстурной сегментации изображений [Текст] / В. Н. Крылов, М. В. Полякова // ААЭК, Информационно-измерительные системы. – 2005. – № 2(16). – С. 40-46.

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

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

10. 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, and Ph. Bunel // *Proc. 7th International Symposium on Signal Processing and Its Applications*. – Vol. 2. – Paris, France, July 2003. – P. 633–635.

11. Image processing with texture feature preservation by three-state locally adaptive filter [Text] / V. V. Lukin, O. V. Tsybmal, N. N. Ponomarenko, K. O. Egiazarian and J. T. Astola // in *Image and Signal Processing for Remote Sensing IX*. - vol. 5238 of *SPIE Proceedings*. – Barcelona, Spain, September 2003. – P. 120–131.

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

13. Adaptive texture-preserving filtering of multi-temporal ERS-1 SAR images [Text] / B. Aiazzi, L. Alparone, S. Baronti, and R. Carla // *Proc. IEEE International Geoscience and Remote Sensing Symposium (IGARSS '97)*. – Vol. 4. – Singapore, August 1997. – P. 2066–2068.

14. HVS-based local analysis of denoising efficiency for DCT-based filters [Text] / O. Rubel, N. Ponomarenko, V. Lukin, K. Egiazarian, J. Astola // *Proceedings of the Conference Problems of Infocommunications. Science and Technology*. – Kharkov, Ukraine, October 2015. – P. 189-192.

15. Perry, S. W. Adaptive Image Processing: A Computational Intelligence Perspective [Text] / S. W.

Perry, H.-S. Wong, L. Guan. - CRC Press, Boca Raton, Fla., USA, 2002. – 376 p.

16. Rubel, A. Efficiency of DCT-based denoising techniques applied to texture images [Text] / A. Rubel, V. Lukin, O. Pogrebniak // *Proceedings of MCPR*. Cancun, Mexico. – No. 8495. – June 2014. – P. 111-120.

17. Efficiency of texture image enhancement by DCT-based filtering [Text] / A. Rubel, V. Lukin, M. Uss, B. Vozel, K. Egiazarian, O. Pogrebnyak // *Neurocomputing*. – Vol. 175. – 2016. – P. 948-965.

18. Lukin, V. HVS-Metric-Based Performance Analysis Of Image Denoising Algorithms [Text] / V. Lukin, N. Ponomarenko, K. Egiazarian // *Proceedings of EUVIP*. – Paris, France, 2011. – P. 156-161.

19. Gilboa, G. Variational Denoising of Partly-Textured Images by Spatially Varying Constraints [Text] / G. Gilboa, N. Sochen, Y.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 // *Proceedings of CVPR*. - Portland, OR, USA, 2013. – 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. Noise identification and estimation of its statistical parameters by using unsupervised variational classification [Text] / B. Vozel, K. Chehdi, L. Klaine, V. V. Lukin, S. K. Abramov // *Proceedings of ICASSP*. – Vol. 2. – Toulouse, France, 2006. – P. 841-844.

24. Image Informative Maps for Component-wise Estimating Parameters of Signal-Dependent Noise [Text] / M. L. Uss, B. Vozel, V. Lukin, K. Chehdi // *Journal of Electronic Imaging*. – 2013. – Vol. 22, no. 1. – P. 1-18.

25. Кривенко, С. С. Обнаружение текстурных участков SVM-классификатором на изображениях при наличии помех [Текст] / С. С. Кривенко, А. В. Науменко, В. В. Лукин // *Радиоэлектронные и компьютерные системы*. – 2015. – № 2(72). – С. 50-57.

26. Scholkopf, B. Learning with Kernels [Text] / B. Scholkopf, A. J. Smola. – MIT Press, Cambridge, MA, 2002. – 38 p.

27. Bishop, C. Pattern Recognition and Machine Learning [Text] / C. Bishop. – Springer Science+Business Media, 2006. – 738 p.

28. Karu, K. Is there any Texture in the Image? [Text] / K. Karu, A. Jain, R. Bolle // *IEEE Pattern recognition 1996 Proceedings*. – Aug 1996. - Vol. 2. – P. 770 -774.

29. SAR image edge detection by ratio-based Harris Method [Text] / X. Kang, C. Han, Y. Yang, T. Tao // *ICASSP 2006 Proceedings*. – May 2006. - Vol. 2. – P. 837 -840.

30. Науменко, А. В. Детектирование границ на изображениях с помощью искусственной нейронной сети [Текст] / А. В. Науменко, В. В. Лукин // *Авиационно-космическая техника и технология*. – 2012. – № 2 (89). – С. 101-110.

31. Ling, C. X. *AUC: a statistically consistent and more discriminating measure than accuracy [Text]* / C. X. Ling, J. Huang, H. Zhang // *Proceedings of IJCAI*. – Acapulco, Mexico, 2003. – P. 519-524.

## References

- Pratt, W. K. *Digital Image Processing*. Fourth Edition. N. Y., Wiley-Interscience Publ., USA, 2007. 1429 p.
- Schowengerdt, R. *Remote Sensing: Models and Methods for Image Processing*. Academic Press, 2006. 560 p.
- Haralick, R., Dori, D. A pattern recognition approach to detection of complex edges. *Pattern Recognit. Lett.* 16, no. 5, 1995, pp. 517–529.
- Haralick, R. M. Textural features for image classification. *IEEE Trans. Syst., Man, Cybern.*, vol. 3, no. 6, 1973, pp. 610–621.
- 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.
- 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.
- 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.
- Leung, T. Representing and recognizing the visual appearance of materials using three-dimensional textons. *Intl. Journal of Computer Vision*, no. 43, 2001, pp. 29–44.
- Micusik, B., Hanbury, A. Supervised texture detection in images. *Proceedings of 11-th International Conference on Computer Analysis of Images and Patterns*, Versailles, France, Sept. 2005, pp. 441-448.
- Nunes, J. C., Niang, O., Bouaoune, Y., Delechelle, E., Bunel, Ph. Texture analysis based on the bi-dimensional 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.
- 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.
- 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.
- Aiazzi B., Alparone, L., Baronti, S., Carla, R. Adaptive texture-preserving filtering of multitemporal ERS-1 SAR images. *Proc. IEEE International Geoscience and Remote Sensing Symposium (IGARSS '97)*, Singapore, vol. 4, August 1997, pp. 2066–2068.
- Rubel, O., Ponomarenko, N., Lukin, V., Egiazarian, K., Astola, J. HVS-based local analysis of denoising efficiency for DCT-based filters. *Proceedings of the Conference Problems of Infocommunications. Science and Technology*. Kharkov, Ukraine, October 2015, pp. 189-192.
- Perry, S. W., Wong, H. S., Guan, L. Adaptive Image Processing: A Computational Intelligence Perspective. *CRC Press Publ.*, Boca Raton, USA, 2002. 376 p.
- 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.
- Rubel, A., Lukin, V., Uss, M., Vozel, B., Egiazarian, K., Pogrebnyak, O. Efficiency of texture image enhancement by DCT-based filtering. *Neurocomputing*, vol. 175, part B, January 2016, pp. 948–965.
- Lukin, V., Ponomarenko, N., Egiazarian, K., HVS-Metric-Based Performance Analysis Of Image Denoising Algorithms. *Proceedings of EUVIP*. Paris, France, 2011, pp. 156-161.
- Gilboa, G., Sochen, N., Zeevi, Y. Y. Variational Denoising of Partly-Textured Images by Spatially Varying Constraints. *IEEE Transactions on Image Processing*, vol. 15, no. 8, 2006, pp. 2281-2289.
- Zuo, W., Zhang, L., Song, C., Zhang, D. Texture Enhanced Image Denoising via Gradient Histogram Preservation. *Proceedings of CVPR*, Portland, OR, USA, 2013, pp. 1203-1210.
- Chatterjee, P., Milanfar, P. Is Denoising Dead? *IEEE Trans. Image Processing*, vol. 19, no. 4, 2010, pp. 895-911.
- Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. Image denoising by sparse 3D transform-domain collaborative filtering. *IEEE Transactions on Image Processing*, vol. 16, no. 8, 2007, pp. 2080-2095.
- Vozel, B., Chehdi, K., Klaine, L., Lukin, V. V., Abramov, S. K. Noise identification and estimation of its statistical parameters by using unsupervised variational classification. *Proceedings of ICASSP*, Toulouse, France, vol. 2, 2006, pp 841-844.
- Uss, M. L., Vozel, B., Lukin, V., Chehdi, K. Image Informative Maps for Component-wise Estimating Parameters of Signal-Dependent Noise. *Journal of Electronic Imaging*, vol. 22, no. 1, 2013, pp. 1-18.
- Krivenko, S. S., Naumenko, A. V., Lukin, V. V. Obnaruzhenie teksturnyh uchastkov SVM-klassifikatorom na izobrazhenijah pri nalichii pomeh

[Detection of texture areas SVM-classifier at the images in the presence of interference], *Radioelektronnye i komp'yuternye sistemy*, no. 2(72), 2015, pp. 50-57.

26. Scholkopf B., Smola, A. J. Learning with Kernels. *MIT Press Publ.*, Cambridge, USA, 2002. 38 p.

27. Bishop, C. Pattern Recognition and Machine Learning. *Springer Science+Business Media, LLC*, 2006. 738 p.

28. Karu, K., Jain, A., Bolle, R. Is there any Texture in the Image? *IEEE Pattern recognition 1996 Proceedings*, vol. 2, 1996, pp. 770 -774.

29. Kang, X., Han, C., Yang, Y., Tao, T. SAR im-

age edge detection by ratio-based Harris Method. *ICASSP 2006 Proceedings*, vol. 2, May 2006, pp. 837-840.

30. Naumenko, A. V., Lukin, V. V. Detektirovanie granic na izobrazhenijah s pomoshh'ju iskusstvennoj nejronnoj seti [Boundaries detection in images using artificial neural network]. *Aviacionno-kosmicheskaja tehnika i tehnologija*, vol. 2, 2012, pp. 101-110.

31. Ling, C., Huang, J., Zhang, H. AUC: a statistically consistent and more discriminating measure than accuracy. *Proceedings of IJCAI*, Mexico, 2003, pp. 519-524.

*Поступила в редакцію 03.02.2016, рассмотрена на редколлегии 18.02.2016*

## ВИЯВЛЕННЯ ТЕКСТУРНИХ ДІЛЯНОК НА ЗОБРАЖЕННЯХ ЗА НАЯВНОСТІ ЗАВАД ЗА ДОПОМОГОЮ КЛАСИФІКАТОРА НА ОСНОВІ НЕЙРОМЕРЕЖІ

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

Проаналізовано можливість виявлення текстурних ділянок на зображеннях, спотворених адитивною некорельованою завадою, класифікатором на основі навченої нейромережі. Досліджено такі набори вхідних параметрів (ознак): відносна локальна дисперсія, детектор Харріса, простий детектор текстур, детектор на основі дискретно-косинусного перетворення. Показано, що характеристики виявлення залежать від кількості вхідних ознак і від того, які саме вхідні параметри використовуються. Обговорено питання навчання нейромережі і застосування навченого класифікатора для обробки зображень з різними текстурами.

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

## NOISY TEXTURES DETECTION USING NEURAL NETWORK CLASSIFICATION

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

The possibility of detecting texture areas of the image distorted by an additive uncorrelated noise has been analyzed with help of the classifier based on neural network learning. We investigated the following sets of input parameters (attributes): relative local variance, Harris detector, simple textures detector, detector based on discrete cosine transform. It is shown that detection performance depends on the number of input characters and on type of used input parameters. Issues of training the neural network and the application of a trained classifier for image processing with different textures are discussed.

**Key words:** texture, detection, image noise, neural network, training

**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

**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

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

**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.

**Naumenko Alexey Vasilyevich** – PhD Student, Dept. of Transmitters, Receivers and Signal Processing, National Aerospace University named after N. Ye. Zhukovsky “KhAI”, Kharkov, Ukraine, e-mail: phist@mail.ru.

**Krivenko Sergey Stanislavovich** – Candidate of Technical Science, Senior Researcher, Dept. of Transmitters, Receivers and Signal Processing, National Aerospace University named after N. Ye. Zhukovsky “KhAI”, Kharkov, Ukraine, e-mail: krivenko.sergiy@gmail.com.

**Zriakhov Mikhail Sergeevich** - Candidate of Technical Science, Associate Professor of Dept. of Transmitters, Receivers and Signal Processing, National Aerospace University named after N. Ye. Zhukovsky “KhAI”, Kharkov, Ukraine, e-mail: zriakhov.ms@gmail.com.

**Lukin Vladimir Vasilyevich** – Doctor of Technical Sciences, Professor of Dept. of Transmitters, Receivers and Signal Processing, National Aerospace University named after N. Ye. Zhukovsky “KhAI”, Kharkov, Ukraine, e-mail: lukin@ai.kharkov.com.