

С.В. ДВОРНИКОВ, Д. В. ВАСИЛЬЕВА
**РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ РАЗЛИВОВ
НЕФТЕПРОДУКТОВ НА ОСНОВЕ КРАТНОМАСШТАБНОЙ
ОБРАБОТКИ ГИСТОГРАММ РАСПРЕДЕЛЕНИЯ ИХ ЯРКОСТИ**

Дворников С.В., Васильева Д. В. Распознавание изображений разливов нефтепродуктов на основе кратномасштабной обработки гистограмм распределения их яркости.

Аннотация. Особую актуальность проблема обнаружения аномалий на обрабатываемых изображениях, получаемых с аппаратуры визуального контроля, приобретает в ходе экологического мониторинга акваторий мирового океана при поиске последствий техногенных катастроф, вызванных разливами нефтепродуктов. Под аномалиями в представленном исследовании рассматриваются фрагменты изображения, характеризующие разливы нефтепродуктов. В качестве предмета исследования определены элементы теории распознавания образов, в соответствии с которыми обрабатываемые изображения представляются в виде векторов признаков. Обоснован выбор гистограмм, характеризующих распределения битов яркости обрабатываемых изображений, которые используются в качестве первичных векторов признаков. Установлено, что высокая вариативность фона изображений водных поверхностей приводит к значительной дисперсии векторов признаков, формируемых на основе гистограмм распределения яркости даже для одного общего класса объектов распознавания. Поэтому предложено подвергать первичные векторы признаков декоррелирующей обработке на основе вейвлет-преобразований. Рассмотрены виды вейвлет-преобразования и различные типы формирующих функций, среди которых обоснован выбор вейвлета Гаусса 1-го порядка, позволившего обеспечить наименьшие различия между векторами признаков обрабатываемых изображений, характеризующих один и тот же класс. Предложен подход к формированию вторичных признаков распознавания путем усреднения компонентов матриц кратномасштабного преобразования гистограмм распределения яркости изображений вдоль оси их параметра сдвига. Обоснован переход к выбору избыточного числа масштабов декомпозиции в вейвлет-преобразованиях при формировании вторичных векторов признаков. Демонстрируются результаты проведенного эксперимента, подтверждающие правомерность такого перехода. Представлены тестовые и эталонные изображения, используемые в ходе эксперимента, а также формируемые на их основе первичные и вторичные векторы признаков. Приведены численные результаты, характеризующие полученную оценку различий векторов признаков как одного класса, так и альтернативных классов. Представлена вероятностная оценка результатов распознавания аномалий на обрабатываемых изображениях. Обосновано использование коэффициента оценки различий векторов признаков в разработанной формуле вероятности правильного обнаружения аномалий в обрабатываемых изображениях. Приведены графики, характеризующие значение вероятностной оценки в зависимости от соотношения размеров аномалии к общей площади кадра для различных значений коэффициента, повышающего различия векторов признаков.

Ключевые слова: аномалии изображений, разливы нефтепродуктов, векторы признаков, распознаваемые классы изображений, гистограммы распределения яркости изображений.

1. Введение. Повышение эффективности экологического мониторинга является одной из глобальных задач, решаемых

международной научной общественностью. Для сбора и констатации фактов, характеризующих последствия загрязнения окружающей среды, службы экологического контроля активно используют системы видеомониторинга. Вместе с тем возрастающий поток видеoinформации существенно усложняет процедуру ее обработки, о чем свидетельствуют результаты исследований, представленных в [1–3], что стимулирует к поиску новых подходов к ее структуризации.

При этом особую актуальность данная проблема приобретает в ходе поиске абстрактных объектов в базах данных обрабатываемых изображений [4, 5]. Примером таких объектов являются результаты разливов нефтепродуктов в акваториях морей и океанов, поскольку они не имеют четкой структуры, позволяющей осуществить их единую формализацию, для последующей обработки на основе методов машинного обучения [6, 7]. Кроме того, сложность своевременного обнаружения результатов такого рода техногенных катастроф усугубляется необходимостью мониторинга огромных площадей контролируемых акваторий [8, 9].

Именно поэтому поиск научных подходов, позволяющих решать задачи обработки изображений в интересах своевременного обнаружения последствий техногенных катастроф, в том числе разливов нефтепродуктов, непосредственно по мере их поступления с аппаратуры фото и видео фиксации, устанавливаемой на летно-подъемных платформах, является актуальной задачей.

Вместе с тем удаленность летно-подъемных платформ от пунктов экологического контроля с телекоммуникационным оборудованием предполагает необходимость организации высокопроизводительных каналов передачи информации [10, 11]. Но это не всегда возможно в силу различных обстоятельств. Поэтому рациональным решением в такой ситуации является предварительная селекция информационных данных непосредственно на борту летно-подъемных платформ, что позволило бы существенно снизить объем передаваемого канального трафика, предоставляемого операторам для принятия решения о результатах обнаружения разлива нефтепродуктов в контролируемых акваториях [12]. Реализация такого подхода видится возможной только при условии наличия высокоэффективных алгоритмов обработки изображений, обеспечивающих автоматическое обнаружение последствий разливов нефтепродуктов. Однако проведенный анализ подходов к организации экологического мониторинга, рассмотренных в [6, 7, 9–11] показал, что они, преимущественно, используют обработку изображений в отложенном режиме на основе методов машинного обучения.

Указанные обстоятельства определяют необходимость поиска и разработки новых методов и способов, позволяющих успешно разрешить рассмотренные проблемы.

Так, в представленной статье демонстрируются возможности предлагаемого метода вероятностной оценки, характеризующего результаты поиска последствий техногенных катастроф, вызванных разливами нефтепродуктов в акваториях морей и океанов, по данным обработки фото и видеоматериалов.

Основной целью исследования является разработка аналитического аппарата, обеспечивающего вероятность правильного обнаружения разливов нефтепродуктов, представляющих собой аномалии обрабатываемых кадров изображений, на уровне 0,93-0,98.

2. Формализация обрабатываемых изображений и формирование первичных векторов признаков. Основополагающим фактором, определяющим достоверность обнаружения объектов на обрабатываемых изображениях, является форма представления исходных данных. Поэтому важным этапом является выбор подхода к их формализации, позволяющей, с одной стороны, получить компактное описание, а с другой стороны, обеспечить существенные различия между изображениями, относящимися к альтернативным классам. В данном разделе представлен подход к формализации обрабатываемых изображений для формирования их первичных векторов признаков.

В [8, 13] обоснована целесообразность представления данных кадров обрабатываемых изображений в виде гистограмм распределения их яркости. Такой выбор, прежде всего, обусловлен не только компактностью представления исходных данных, но и достаточно высокой их чувствительностью к возникновению аномалий [14, 15]. Под аномалиями в рамках проведенного исследования будем понимать фрагмент изображения, вызванный последствием разливов нефтепродуктов в контролируемой акватории [8].

В качестве примера на рисунке 1 демонстрируются изображения формата *.jpeg с разрешением 640×480 , на которых представлены фрагменты акватории Черного моря, без разливов нефтепродуктов (Рис. 1(а)) и с последствиями техногенной катастрофы (Рис. 1(б)).

На рисунке 2 изображены, соответственно, матрицы амплитудных значений изображений, представленных на рисунке 1.

Очевидно, что такой формат представления данных достаточно громоздкий для его обработки, требующий существенных вычислительных ресурсов при формировании векторов признаков, имеющих $307 \cdot 200$ элементов. Переход к векторному представлению

за счет усреднения амплитудных значений матриц вдоль одной из осей ведет к снижению информативности такого представления, что является нежелательным моментом [16, 17].

Вместе с тем в [18] обосновано представление изображений для их последующей обработки в виде векторов распределения яркости.

Учитывая, что при 8-битовом кодировании яркость представляется всего лишь 256 значениями, то вектор будет иметь такую же размерность. На рисунке 3 представлены гистограммы распределения яркости для ТИ-1 и ТИ-2 (далее по тексту – гистограммы) в одинаковом масштабе.




Рис. 1. Тестовое изображение: а) ТИ-1; б) ТИ-2




Рис. 2. Матрица амплитудных значений тестового изображения:
а) ТИ-1; б) ТИ-2




Рис. 3. Гистограмма тестового изображения: а) ТИ-1; б) ТИ-2

Согласно результатам исследования, представленным в [6, 8, 17], векторы признаков, сформированные на основе гистограмм, обеспечивают наилучшие различия по отношению к другим форматам представления амплитудных значений матрицы обрабатываемых изображений. Однако высокая вариативность водной поверхности даже в условиях отсутствия разливов нефтепродуктов приводит к тому, что характеризующие их изображения векторов признаков на основе гистограмм распределения яркости имеют весьма высокую дисперсию, существенно усложняющую получения высоких результатов достоверности выявления аномалий [6].

В частности, для эталонного изображения ТИ-1 (Рис. 1(а)) с водной поверхностью, не загрязненной разливами нефтепродуктов, были подготовлены кадры с различной освещенностью при незначительном изменении характера волнения. Всего для эксперимента было подготовлено 200 кадров, из которых для исследования были отобраны тестовые изображения ТИ-11, ТИ-12, ТИ-13 и ТИ-14 (Рис. 4). И соответствующие им векторы признаков $H_{\text{ТИ-11}}$, $H_{\text{ТИ-12}}$, $H_{\text{ТИ-13}}$, $H_{\text{ТИ-14}}$ (Рис. 5).

Тестовые изображения отбирались следующим образом. Подготовленные 200 кадров первоначально были разделены на четыре группы, в зависимости от величины разброса компонентов их гистограмм яркости. Затем из каждой группы были отобраны изображения, имеющие наибольшие разбросы компонент яркости в пределах каждой из групп. Таковыми явились тестовые изображения ТИ-11, ТИ-12, ТИ-13 и ТИ-14. Последующий выбор изображения ТИ-1 в качестве эталонного обусловлен тем, что оно характеризует фрагмент водной акватории вблизи разливов нефтепродуктов.

Сопоставительный анализ тестовых изображений и соответствующих им гистограмм позволяет сделать следующее заключение: формирование устойчивых векторов признаков, характеризующих один и тот же класс распознаваемых объектов (водную акваторию без разливов нефтепродуктов), связано

с определенными сложностями, обусловленными значительным разбросом амплитудных значений их гистограмм.




Рис. 4. Тестовое изображение: а) ТИ-11; б) ТИ-12; в) ТИ-13; г) ТИ-14




Рис. 5. Гистограмма тестового изображения:
а) ТИ-11; б) ТИ-12; в) ТИ-13; г) ТИ-14

Заметим, что изменение освещенности ведет к увеличению амплитудных значений слева и справа от основного тренда (смещение в сторону нуля происходит при затемнении, а в сторону 255 – при повышении освещенности). Следовательно, любое изменение освещенности объекта по отношению к исходному изображению ведет к увеличению разброса компонентов яркости.

В качестве примера оценим вариативность гистограмм $H_{\text{ТИ-11}}$, $H_{\text{ТИ-12}}$, $H_{\text{ТИ-13}}$, $H_{\text{ТИ-14}}$, характеризующих тестовое изображение ТИ-1 в других условиях освещенности. Для этого построим функцию различий в соответствии с выражением:

$$\Delta r_{0,N}(k) = |H_{\text{ТИ-1}}(k) - H_{\text{ТИ-N}}(k)|, \quad (1)$$

где N – текущий номер гистограммы обрабатываемого изображения, сравниваемый с гистограммой изображения ТИ-1.

На рисунке 6 представлены графики функций различий $\Delta r_{0,N}(k)$, для гистограмм тестовых изображений ТИ-11, ТИ-12, ТИ-13 и ТИ-14.

На рисунке 6 введены следующие обозначения:

$\Delta r_{0,1}(k)$ – функция различий между изображением ТИ-1 и ТИ-11;

$\Delta r_{0,2}(k)$ – функция различий между изображением ТИ-1 и ТИ-12;

$\Delta r_{0,3}(k)$ – функция различий между изображением ТИ-1 и ТИ-13;

$\Delta r_{0,4}(k)$ – функция различий между изображением ТИ-1 и ТИ-14;

$\Delta r_{0,0}(k)$ – усредненная функция различий.

Следует отметить, что все рассчитанные функции различий равны нулю в тех позициях, где элементы гистограмм как эталонного, так и текущего описания равны нулю, а также в позиции совпадения их максимальных значений. На рисунке 6 представлена и усредненная функция различий $\Delta r_{0,0}(k)$. Ее положение как раз и позволяет оценить параметры вариативности. Для оценки усредненной функции различий рассмотренных изображений дополнительно были рассчитаны функции, характеризующие ее границы сверху и снизу (Рис. 7).

В таблице 1 приведены результаты оценки различий гистограмм тестовых изображения, полученных на основе выражений:

$$\Delta r = \overline{|H_{\text{ТИ-1}} - H_{\text{ТИ-N}}|}, \quad (2)$$

$$\Delta r [\%] = \overline{|H_{\text{ТИ-1}} - H_{\text{ТИ-N}}|} \times \left(\sum_{k=0}^{255} H_{\text{ТИ-1}}(k) \right)^{-1} \times 100\%. \quad (3)$$




Рис. 6. Графики функций различий гистограмм тестовых изображений по отношению к эталонному описанию ТИ-1




Рис. 7. График усредненной функции различий

В формулах (2) и (3) представлена операция поэлементного вычитания векторов $H_{\text{ТИ-1}} - H_{\text{ТИ-N}}$.

Величина $H_{\text{ТИ-1}} - H_{\text{ТИ-2}}$, характеризующая различия между эталонным изображением ТИ-1 и изображением с разливами нефтепродуктов ТИ-2, рассчитанная в соответствии с выражением (3), составляет 7,6%.

Таблица 1. Оценка различий гистограмм тестовых изображений

Различия гистограмм	$H_{\text{ТИ-1}} - H'_{\text{ТИ-11}}$	$H_{\text{ТИ-1}} - H_{\text{ТИ-12}}$	$H_{\text{ТИ-1}} - H_{\text{ТИ-13}}$	$H_{\text{ТИ-1}} - H_{\text{ТИ-14}}$
Δr	1,187	2,031	0,815	0,782
$\Delta r, \%$	2,5	4,3	1,7	1,6

Отметим, что для рассматриваемых тестовых изображений величина разброса функции различий, согласно таблице 1, достигает 4%. Очевидно, что при более сильном освещении (затемнении) изображения на кадре по отношению к исходному, рассмотренный эффект усилится.

Вместе с тем, согласно [6], даже при величине разброса функции различий порядка 4% потенциальная вероятность правильного обнаружения не превысит значения 0,96. Для усредненной функции различий гистограмм среднее значение Δr будет равно 1,204. А общая величина разброса достигает значения 0,338.

Тогда, если для обнаружения разливов нефтепродуктов использовать ранговый классификатор, то аналитический алгоритм принятия решения можно представить в следующем виде:

$$A_0 \underset{A_1}{\overset{A_2}{>}} 0, \quad (4)$$

где,

$$A_0 = (d_{01} - d_{02}).$$

Здесь: d_{01} – нормированная абсолютная величина различий между вектором эталонного описания $H_{\text{ТИ-1}}$, принадлежащего классу A_1 , соответствующего изображению с отсутствием разливов нефтепродуктов, и одного из векторов обрабатываемых изображений $H_{\text{ТИ-N}}$ этого же класса A_1 ; M – размерность векторов; d_{02} – нормированная абсолютная величина различий между вектором эталонного описания $H_{\text{ТИ-1}}$, принадлежащего классу A_1 , и одного из векторов обрабатываемых изображений $H_{\text{ТИ-N}}$, принадлежащих классу A_2 , т.е. к классу, который характеризует изображения с разливами нефтепродуктов.

Расчет значений d_{01} и d_{02} осуществляют в соответствии с одним и тем же выражением:

$$d_{01(02)} = \frac{1}{M} \sum_{k=1}^M |H_{\text{ТИ-1}}(k) - H_{\text{ТИ-N}}(k)|. \quad (5)$$

Рассмотренный подход к формализации изображений в виде гистограмм распределения яркости позволяет формировать векторы

признаков, которые удобно использовать в ранговых классификаторах. Однако такие вектора признаков весьма чувствительны к изменению освещенности объектов, что затрудняет получение устойчивого эталонного описания, и как результат – высокой достоверности распознавания.

Следовательно, для повышения достоверности необходим поиск подходов к снижению вариативности векторов признаков, характеризующих один и тот же класс распознаваемых изображений.

3. Предложение по снижению вариативности векторов признаков на основе кратномасштабной обработки гистограмм.

Одной из причин высокой вариативности гистограмм является изначальная избыточность тестовых изображений, обусловленная достаточно сильной пространственной корреляцией их элементов [15, 19]. Поэтому предлагается к формируемым на их основе гистограммам распределения яркости применить декоррелирующие преобразования.

Согласно [20], основной задачей декоррелирующих преобразований является снижение объема представляемых для обработки данных при сохранении их информационного наполнения.

Среди декоррелирующих преобразований широкое распространение получили следующие: сингулярное преобразование [21]; дискретное преобразование Карунена-Лоэва [22]; дискретное косинусное преобразование [23]; и дискретное вейвлет-преобразование [24]. Вместе с тем анализ результатов исследования [25–29] показал, что для изображений с высокой динамикой изменения фона указанные декоррелирующие преобразования проигрывают ДВП по компактности представления, ошибки аппроксимации и помехоустойчивости. При этом, согласно результатам исследований, представленным в [30], ДВП является наиболее эффективным декоррелирующим преобразованием, обеспечивающим наилучшие различия между векторами признаков, характеризующим альтернативные классы при минимизации их размерности.

В общем случае дискретное вейвлет-преобразование представляет собой результат декомпозиции обрабатываемого процесса в базисах вейвлет-функций (англ. *wavelet*) [31].

Свойство масштабируемости вейвлет-функций открывает возможность локализовать различные по характеру изменения исследуемого процесса в соответствующих проекциях масштаба, что позволяет рассматривать их при одинаковом разрешении, независимо от реальных размеров. В общем случае реализация ДВП $W(k, n)$ представляет собой свертку входной реализации

обрабатываемого процесса $x(t)$ и формирующего материнского вейвлета $\psi(t)$ [32]:

$$W(k, n) = \frac{1}{\sqrt{2^k}} \int_0^{N-1} x(t) \psi\left(\frac{t-2^k n}{2^k}\right) dt, \quad (6)$$

где n – переменная сдвига; k – переменная масштаба; N – величина временного интервала обработки.

Таким образом, в соответствии с (6), ДВП представляет собой результат декомпозиции входного процесса путем его последовательной ВЧ и НЧ-фильтрации с временным сдвигом n и кратномасштабным изменением амплитудно-частотной характеристики НЧ-фильтра $g(2n - t)$ и ВЧ-фильтра $h(2n - t)$.

При этом результат ВЧ-фильтрации $h(2n - k)$ позволяет получить детализирующие значения, определяемые как вейвлет-коэффициенты $y_{ВЧ}(n)$, а НЧ-фильтрация $g(2n - t)$ ведет к формированию аппроксимирующих коэффициентов $y_{НЧ}(n)$:

$$y_{НЧ}(n) = \sum_{t=0}^{N-1} x(t) g(2n - t), y_{ВЧ}(n) = \sum_{t=0}^{N-1} x(t) h(2n - t). \quad (7)$$

Фильтры, описываемые посредством выражений (10), получили название квадратурных зеркальных фильтров [33]. Последовательная реализация процедур, в соответствии с выражениями (10), ведет к формированию двумерной матрицы вейвлет-коэффициентов, которая представляет собой дискретное вейвлет-преобразование [34].

С представленных позиций ДВП можно рассматривать как распределение энергии (в рассматриваемом случае амплитудных значений гистограмм) в пространстве их масштабных преобразований и временных сдвигов, реализуемых на основе формирующих (порождающих) материнских вейвлетов.

Вместе с тем, анализ выражения (6) показывает, что ДВП обеспечивает кратномасштабный сдвиг, пропорциональный множителю 2^k , в пределах которого как раз и происходит усреднение обрабатываемых значений вдоль оси n . Для исключения потери информативности первичных векторов признаков в результате их усреднения на каждом последующем сдвиге 2^k , без потери общности воспользуемся непрерывной формой кратномасштабного вейвлет-преобразования, определяемого следующим выражением [31]:

$$W(k, n) = \frac{1}{\sqrt{k}} \int_0^{N-1} x(t) \psi\left(\frac{t-n}{k}\right) dt. \quad (8)$$

Отметим, что кратномасштабное преобразование, описываемое выражением (8), также позволяет формировать двумерные матрицы вейвлет-коэффициентов, структура которых будет определяться типом формирующей вейвлет-функции $\psi(*)$.

Свойства вейвлет-преобразований во многом определяются выбором исходной порождающей функции. Это обусловлено тем, что по своей сущности матрица кратномасштабного преобразования представляет собой результат корреляции обрабатываемых данных с различными формами материнского вейвлета. При этом формы порождающей функции формируют в результате изменения коэффициента частотного масштаба и временного сдвига. Поэтому необходимо среди множества видов материнских вейвлетов выбрать тот, который позволит формировать кратномасштабные преобразования векторов признаков обрабатываемых изображений, наиболее соответствующие решаемым задачам. Простейшей формирующей функцией (далее по тексту – материнский вейвлет), используемой для кратномасштабного преобразования, является вейвлет Хаара, описываемый следующим выражением [35]:

$$\psi_X(t) = \begin{cases} 1, & 0 \leq t < 0,5; \\ -1, & 0,5 \leq t < 1; \\ 0, & t \notin [0, 1). \end{cases} \quad (9)$$

А масштабирующая функция для вейвлета Хаара (далее по тексту – отцовский вейвлет) определяется формулой:

$$\varphi_X(t) = \begin{cases} 1, & 0 \leq t < 1; \\ 0, & t \notin [0, 1). \end{cases} \quad (10)$$

Здесь и далее нижний индекс $\psi(*)$ (t) определяет первую букву названия функции вейвлета.

В соответствии с аналитической формой представления формирующей функции вейвлета Хаара $\psi_X(t)$ (9), элементы входной реализации группируются по два. А затем для каждой группы вычисляется их сумма и разность. Указанная последовательность процедур реализуется рекурсивно, с образованием нового уровня масштабного преобразования в пространстве временных сдвигов [32].

В результате выполнения указанных процедур получают 2^{k-1} уровней декомпозиций и одну общую сумму в виде ошибки (остатка) аппроксимации.

В ДВП активное применение находят вейвлеты Добеши. Это семейство ортогональных функций, не имеющие аналитического описания, коэффициенты которых рассчитывают на основе итерационных алгоритмов. Представляют их следующим образом [36]:

$$\psi_D(n) = \sqrt{2} \sum_{t=0}^{N-1} g_t \varphi(2n - t), \quad (11)$$

$$\varphi_D(n) = \sqrt{2} \sum_{t=0}^{N-1} h_t \varphi(2n - t). \quad (12)$$

Расчет отцовского вейвлета $\varphi(n)$ происходит при использовании вычисленных значений ортогональных нормированных коэффициентов, получивших название коэффициенты Добеши низких порядков [36]. В частности, на рисунке 9 представлены формирующий и масштабирующий вейвлеты Добеши $\psi_D(n)$ и $\varphi_D(n)$ 4-го порядка.

Поскольку масштабирующая функция (отцовский вейвлет) служит для построения кратномасштабного базиса декомпозиции с возможностью последующего восстановления анализируемого процесса, что не является предметом данного исследования, то в дальнейшем будем рассматривать лишь формирующие материнские функции основных видов вейвлетов.

Для дискретных данных достаточно часто используют, так называемые, дуальные (двойные) вейвлеты, синтезируемые на основе передаточных характеристик низкочастотных и высокочастотных фильтров, или R -функций, связанных следующим условием [37]:

$$\psi_{Dв}(n) = \varphi_{Dв}(n) + z\varphi_{Dв}(2n), \quad (13)$$

где z – некоторое комплексное число.

В обработке изображений широкое применение находят биортогональные вейвлеты (B -сплайновые (англ. *B-spline*) вейвлеты) [38]. Главная особенность биортогональных вейвлетов заключается в том, что формируемый на их основе кратномасштабный базис не является ортогональным [37]. Однако применение биортогональных вейвлетов допускает больше возможных степеней свободы для построения симметричных вейвлет-функций.

В преобразованиях на основе биортогональных вейвлетов применяют две формирующие ψ_B , ψ'_B и две масштабирующие φ_B , φ'_B функции.

Аналитически это можно представить следующим образом:

$$\varphi_B(n) = \sum_{t=0}^{N-1} p_t \varphi(2n - t), \quad \varphi'_B(n) = \sum_{t=0}^{N-1} p'_t \varphi'(2n - t), \quad (14)$$

$$\begin{aligned} \psi_B(n) &= \sum_{t=0}^{N-1} (-1)^{t+1} p_{-t+1} \varphi(2n - t), \\ \psi'_B(n) &= \sum_{t=0}^{N-1} (-1)^{t+1} p_{-t+1} \varphi'(2n - t). \end{aligned} \quad (15)$$

В (17) и (18) коэффициенты p_t и p'_t являются расчетными, значения которых представлены в [39]. Наиболее широкое применение в кратномасштабном анализе получили вейвлеты Гаусса различных порядков [26, 28, 30, 31, 40]. В аналитическом виде вейвлет Гаусса n -го порядка можно представить на основе следующего выражения:

$$\psi_{\Gamma n}(t) = (-1)^n \frac{d^n}{dt^n} \exp(-t^2/2), \quad (16)$$

где n – порядок дифференцирования.

Согласно выражению (16) повышение порядка дифференцирования ведет к увеличению количества осцилляций функции на длительности ее элемента. Поэтому учитывая, что гистограммы представляют собой векторы дискретных значений, применение вейвлет-функций выше 2-го порядка не целесообразно.

С учетом такого ограничения, аналитические выражения, описывающие вейвлеты Гаусса 1-го и 2-го порядка, будут иметь вид:

$$\psi_{\Gamma 1}(t) = -t \exp(-t^2/2), \quad (17)$$

$$\psi_{\Gamma 2}(t) = (1 - t^2) \exp(-t^2/2). \quad (18)$$

4. Результаты эксперимента. В интересах выбора вида формирующей вейвлет-функции для дальнейшего исследования были отобраны два изображения ТИ-1 и ТИ-12, которые характеризуют один и тот же альтернативный класс, но при этом ТИ-12, согласно таблице 1, имеет наибольшие различия с ТИ-1, по отношению к другим рассматриваемым изображениям.

На рисунках 8 и 9 представлены матрицы кратномасштабного преобразования (КМП) гистограмм тестовых изображений ТИ-1 и ТИ-12, рассчитанные на основе алгоритма, реализующего выражение (6) для рассмотренных выше формирующих вейвлет-функций.

На рисунках 8 и 9 (и далее) верхний левый индекс в обозначении матрицы указывает на тип формирующего вейвлета: Х – вейвлет Хаара; Г1 – вейвлет Гаусса 1-го порядка; Г2 – вейвлет Гаусса 2-го порядка; Д – вейвлет Добеши 4-го порядка; Б – биортогональный вейвлет; Дв – дуальный (двойной) вейвлет.

Матрицы кратномасштабного преобразования, представленные на рисунках 8 и 9, построены с 4-х кратным прореживанием по оси времени, для лучшей наглядности их структуры. Дальнейшие расчеты будут представлены для полноразмерных матриц.

Проведенный визуальный анализ сформированных матриц указывает на то, что кратномасштабное преобразование тестового изображения ТИ-12 имеет ярко выраженные коэффициенты в интервале значений параметра $n \in [245; 255]$ в отличие от матриц эталонного изображения ТИ-1. Именно эти коэффициенты как раз и приводят к высокой дисперсии различий гистограмм ТИ-1 и ТИ-12.

Формируемые матрицы имеют две координаты по оси k и оси n , что открывается возможность построения вторичных векторов признаков путем их усреднения или вдоль оси пространственного сдвига n или вдоль оси масштабирования k . На рисунке 10 представлены вторичные векторы признаков, формируемые путем усреднения вдоль оси пространственного сдвига n для матрицы изображения ТИ-1.

На рисунке 11 демонстрируются вторичные векторы признаков, формируемые путем усреднения вдоль оси масштабирования k для матрицы изображения ТИ-1.

Поскольку для исследования значение имеет не сам вид матрицы преобразования в соответствии с выбранным видом вейвлет-функции, а возможность снизить разброс формируемых на ее основе векторов признаков, описывающих изображения, характеризующих один и тот же распознаваемый класс, то для сравнительной оценки аналогичным образом были построены вторичные векторы признаков по тестовому изображению ТИ-12.

Важно отметить, что причиной выбора для исследования гистограммы тестового изображения ТИ-12 послужило то, что она имеет наибольшие структурные отличия от гистограммы эталонного изображения ТИ-1.

В таблице 2 приведены значения оценки различий гистограмм, полученных на основе выражения (2), для эталонного изображения ТИ-1 и тестового изображения ТИ-12, сформированных в различных базисах вейвлет-функций.

В последнем столбце приведены значения разности вторичных векторов признаков между эталонным изображением и изображением ТИ-2, характеризующим результаты разливов нефтепродуктов.




Рис. 8. Трехмерная матрица КМП гистограммы изображения ТИ-1 на основе: а) вейвлета Хаара; б) вейвлета Гаусса 1-го порядка; в) вейвлета Гаусса 2-го порядка; г) вейвлета Добеши 4-го порядка; д) биортогонального вейвлета; е) дуального вейвлета




Рис. 9. Трехмерная матрица КМП гистограммы изображения ТИ-12 на основе: а) вейвлета Хаара; б) вейвлета Гаусса 1-го порядка; в) вейвлета Гаусса 2-го порядка; г) вейвлета Добеши 4-го порядка; д) биортогонального вейвлета; е) дуального вейвлета




Рис. 10. Вектор средних значений матрицы КМП на основе:
 а) вейвлета Хаара изображения ТИ-1 (по оси n);
 б) вейвлета Гаусса 1-го порядка изображения ТИ-1 (по оси n);
 в) вейвлета Гаусса 2-го изображения ТИ-1 (по оси n);
 г) вейвлета Добеши 4-го порядка изображения ТИ-1 (по оси n);
 д) биортогонального вейвлета ТИ-1 (по оси n);
 е) дуального вейвлета изображения ТИ-1 (по оси n)




Рис. 11. Вектор средних значений матрицы КМП на основе:

- а) вейвлета Хаара изображения ТИ-1 (по оси k);
- б) вейвлета Гаусса 1-го порядка изображения ТИ-1 (по оси k);
- в) вейвлета Гаусса 2-го изображения ТИ-1 (по оси k);
- г) вейвлета Добеши 4-го порядка изображения ТИ-1 (по оси k);
- д) биортогонального вейвлета ТИ-1 (по оси k);
- е) дуального вейвлета изображения ТИ-1 (по оси k)

Таблица 2. Разность векторов признаков изображений ТИ-1 и ТИ-12, полученных усреднением матрицы КМП гистограммы по оси n

Матрицы КМП	$X_{V_{TI-1}} - X_{V_{TI-12}}$	$\Gamma^1 V_{TI-1} - \Gamma^1 V_{TI-12}$	$\Gamma^2 V_{TI-1} - \Gamma^2 V_{TI-12}$	$D^1 V_{TI-1} - D^1 V_{TI-12}$	$B^1 V_{TI-1} - B^1 V_{TI-12}$	$D^2 V_{TI-1} - D^2 V_{TI-12}$	$\Gamma^1 V_{TI-1} - \Gamma^1 V_{TI-2}$
Δr	2,586	2,972	3,179	2,365	2,963	2,704	4,533
$\Delta r, \%$	6,3	6,0	8,0	9,9	8,5	9,8	9,5

Представленные расчеты проведены в соответствии с выражениями (2) и (3). В таблице 3 представлены значения разности между векторами эталонного ТИ-1 и тестового ТИ-12 изображений, сформированных в различных базисах вейвлет-функций, но усредненных по оси масштабирования k .

Таблица 3. Разность векторов признаков изображений ТИ-1 и ТИ-12, полученных усреднением матрицы КМП гистограммы по оси k

Матрицы КМП	${}^X V_{\text{ТИ-1}} - {}^X V_{\text{ТИ-12}}$	${}^{\Gamma^1} V_{\text{ТИ-1}} - {}^{\Gamma^1} V_{\text{ТИ-12}}$	${}^{\Gamma^2} V_{\text{ТИ-1}} - {}^{\Gamma^2} V_{\text{ТИ-12}}$	${}^D V_{\text{ТИ-1}} - {}^D V_{\text{ТИ-12}}$	${}^B V_{\text{ТИ-1}} - {}^B V_{\text{ТИ-12}}$	${}^{D^B} V_{\text{ТИ-1}} - {}^{D^B} V_{\text{ТИ-12}}$	${}^{\Gamma^1} V_{\text{ТИ-1}} - {}^{\Gamma^1} V_{\text{ТИ-2}}$
Δr	1,649	0,204	0,33	1,423	1,575	1,506	0,536
$\Delta r, \%$	37,7	4,0	8,2	28,2	37,4	36,6	10,5

Анализ полученных результатов показывает, что наилучший результат обеспечивает кратномасштабная обработка гистограмм в базисе вейвлета Гаусса 1-го порядка, так как он обеспечил наименьшие различия между эталонным изображением ТИ-1 и тестовым изображением ТИ-12. Следует отметить, что ТИ-12 было отобрано как изображение, имеющее наибольшие различия в структуре гистограммы по отношению к гистограмме эталона ТИ-1 среди 200 отобранных тестовых изображений.

Переход к оценке, отражающей разницу векторов признаков, выраженную в процентах по отношению к эталонному значению, обусловлен различием амплитудных значений коэффициентов, сформированных в различных функциональных базисах.

5. Обоснование размерности матрицы кратномасштабного преобразования для построения векторов признаков. Проведенный дополнительный анализ показал, что декоррелирующая обработка гистограмм, наряду с уменьшением абсолютных различий между векторами изображений ТИ-1 и ТИ-12 в пределах одного альтернативного класса, привела к снижению различий между векторами различных классов, что является негативным моментом.

Следовательно, необходим поиск научных решений, позволяющих не только снизить дисперсию векторов признаков изображений, принадлежащих одному классу, но и повысить общие различия признакового пространства, под которым в [41] определены абсолютные наименьшие различия между векторами признаков, описывающих любые альтернативные классы.

В интересах реализации данной концепции предложено изменить масштабирующий множитель 2^k в выражения (8). Это обусловлено тем, что в рассматриваемой ситуации выбор значения масштаба не является принципиальным моментом. Так как размерность гистограммы в общем случае может быть любой, то предлагается в выражении (8) вейвлет $\psi(*)$ масштабировать произвольным образом. В качестве примера на рисунке 12 представлены матрицы КМП эталонного изображения ТИ-1,

Таблица 5. Оценка различий векторов признаков
тестовых изображений для $k = 32$

Матрицы КМП	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-21}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-22}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-23}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-24}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-25}}$
Δr	1,376	1,601	0,84	0,795	5,408
$\Delta r, \%$	1,7	2,0	1,1	0,9	6,8

Таблица 6. Оценка различий векторов признаков
тестовых изображений для $k = 64$

Матрицы КМП	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-21}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-22}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-23}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-24}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-25}}$
Δr	1,609	1,878	0,651	0,486	6,041
$\Delta r, \%$	1,3	1,5	0,5	0,4	4,9

Таблица 7. Оценка различий векторов признаков
тестовых изображений для $k = 128$

Матрицы КМП	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-21}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-22}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-23}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-24}}$	$\Gamma^1 V_{\text{ТИ-20}} - \Gamma^1 V_{\text{ТИ-25}}$
Δr	1,618	2,37	0,591	0,526	4,927
$\Delta r, \%$	0,9	1,3	0,33	0,29	2,7

Значения $\Delta r, \%$ в таблицах 4-7 рассчитаны в соответствии с выражением:

$$\Delta r = \frac{|\Gamma^1 V_{\text{ТИ-1}} - \Gamma^1 V_{\text{ТИ-**}}|}{\sum_{n=0}^{N-1} \Gamma^1 V_{\text{ТИ-1}}(n)} \times 100\%, \quad (19)$$

где $\Gamma^1 V_{\text{ТИ-**}}$ – вторичный вектор признаков текущего тестового изображения, сравниваемого с аналогичным вектором эталонного описания ТИ-1; $|\Gamma^1 V_{\text{ТИ-1}} - \Gamma^1 V_{\text{ТИ-**}}|$ – модуль разницы векторов.

Выражение (19) является модификацией формулы (3) при переходе от гистограмм тестовых изображения к вторичным векторам признаков изображений. Для окончательного выбора размерности матрицы кратномасштабного преобразования, необходимой для формирования векторов признаков, воспользуемся формулой:

$$\delta_k = \frac{\Delta r_{\text{ТИ-1,ТИ-2}}}{\Delta r_{\text{ТИ-1,ТИ-12}}}, \quad (20)$$

где $\Delta r_{\text{ТИ-1,ТИ-2}}$ и $\Delta r_{\text{ТИ-1,ТИ-12}}$ – расчетные значения из таблиц 4-7.

Результаты расчетов значения δ при различной величине k , представлены в таблице 8. Полученный результат характеризует различия векторов признаков изображений, используемых при обнаружении аномалий для рассматриваемых условий.

Таблица 8. Оценка различий векторов признаков для различных k

Размерность вектора	Для $k = 8$	Для $k = 16$	Для $k = 32$	Для $k = 64$	Для $k = 128$
δ_k	1,77	1,93	3,4	3,27	2,08

Согласно результатам, представленным в таблице 8, наилучшие различия между вторичными векторами признаков для рассматриваемых изображений обеспечивают векторы, полученные усреднением по оси временных сдвигов матриц КМП размерностью 256×32 , полученных на основе вейвлетов Гаусса 1-го порядка.

И хотя полученный результат в общем случае применим для используемых в исследовании изображений, он позволяет сделать следующее заключение: применение процедур кратномасштабной обработки позволяет повысить различие векторов признаков.

Для оценки эффективности представленного подхода предложено ввести коэффициент повышения различий (КПР) $K_{\text{ПК}}$, значение которого определяется следующей формулой:

$$K_{\text{ПК}} = \frac{d_{H_3, H_T}}{d_{V_3, V_T}}, \quad (21)$$

где d_{H_3, H_T} – разность значений элементов гистограмм эталонного и текущего изображений до реализации процедур КМП; d_{V_3, V_T} – разность, полученная после реализации указанных процедур.

Результаты расчета КПР для $k = 32$ дают значение $K_{\text{ПК}} = 3,4$.

Тогда формула оценки вероятности правильного обнаружения аномалий с учетом коэффициента оценки различий, полученная в [6], будет иметь вид:

$$P_{\text{по}} = \begin{cases} 0,5 \left[1 + \Phi \left(\frac{\delta_A K_{\text{ПК}} - \sigma_p^2}{\sigma_p^2} \right) \right], & \frac{\delta_A K_{\text{ПК}}}{\sigma_p^2} \geq \sigma_p^2 \\ 0,5 \left[1 - \Phi \left(\frac{\sigma_p^2 - \delta_A K_{\text{ПК}}}{\sigma_p^2} \right) \right], & \frac{\delta_A K_{\text{ПК}}}{\sigma_p^2} < \sigma_p^2 \end{cases}, \quad (22)$$

где δ_A – коэффициент, характеризующий относительные размеры аномалии к общей площади кадра обрабатываемого изображения,

$\delta_A \in [0; 1]$; σ_p^2 – дисперсия различий между векторами признаков эталонного изображения и текущего; σ_z^2 – дисперсия вектора признаков изображения, рассматриваемого в качестве эталонного.

В интересах оценки влияния значения КПР на величину вероятности правильного обнаружения, на рисунке 13 представлены графики $P_{по}(\delta_A)$ для значений $K_{ПК} = 1; 1,5; 3,4$.




Рис. 13. Графики вероятности правильного обнаружения аномалии изображения при различных значениях $K_{ПК}$

Графики, представленные на рисунке 13 получены для условия $\sigma_p^2 = 0,3$; пунктиром показан уровень, соответствующий вероятности правильного распознавания равно $P_{по} = 0,95$.

Следует отметить, что при $K_{ПК} = 1,5$ заданное значение вероятности $P_{по} = 0,95$ будет обеспечено при снижении размера аномалии в 1,5 по отношению к условиям, при которых $K_{ПК} = 1$ (точки C_3 и C_2).

В тоже время повышение различий до $K_{ПК} = 3,4$, позволит обнаруживать аномалии в 3,3 раза меньшего размера с тем же значением вероятности. Результат подтвержден по результатам обработки 252 фрагментов различных изображений при значении вероятности правильного обнаружения $P_{по} = 0,93-0,98$.

6. Анализ возможностей методов машинного обучения в решении задач обнаружения разливов нефтепродуктов.

Альтернативным подходом к решению задачи обнаружения разливов нефтепродуктов является применение методов машинного обучения.

Анализ работ [42–45], посвященных разработке и исследованию возможностей глубоких сверточных нейронных сетей CNNs, позволил обобщить сведения об их эффективности и производительности применительно к задачам обнаружения разливов нефтепродуктов, которые сведены в таблице 9.

Таблица 9. Параметры эффективности и производительность нейронных сетей

Тип сети	AlexNet	VGG-16	GoogLeNet	ResNet	SENet
Число операций	724×10^6	$15,5 \times 10^9$	$1,43 \times 10^9$	$3,6 \times 10^9$	$5,8 \times 10^9$
Достоверность	0,84	0,92	0,93	0,96	0,965

При этом размеры изображений в среднем составили всего 227×227 пикселей. А распознаванию подвергались детерминированные объекты. Наибольшие успехи в решении задач экологического мониторинга отмечены в [46], где решалась задача поиска разливов нефтепродуктов на основе нейронных сетей глубокого обучения по результатам обработки изображений из баз данных Европейского космического агентства, полученных от спутникового радара с синтезированной апертурой (*Synthetic Aperture Radar* – SAR).

Обработке подвергались фрагменты изображений с разрешением 1252×609 пикселей. При этом в ходе эксперимента были определены два эталонных класса изображений: разливы нефтепродуктов; отсутствие разливов.

Результаты работы классификатора представлены в таблице 10.

Таблица 10. Результаты классификации при выделении трех семантических сегментов

Вид семантического сегмента	Overall	Oil spills	Look-alikes
Достоверность классификации	0,8063	0,8621	0,7588

В таблице 10 использованы следующие обозначения: overall – общая вероятность классификации изображения; oil spills – достоверное наличие разливов нефтепродуктов; Look-alikes – полное совпадение результатов работы сети с данными визуального анализа.

При этом допустимый порог классификации для разделения классов составлял порядка 2% пикселей, соответствующих альтернативному классу. Следует отметить, что применение для решения данной задачи алгоритма tree forest позволило повысить точность классификации до 0,85. К сожалению, доступ к базам данных Европейского космического агентства закрыт, что не позволяет осуществить непосредственную проверку разработанного подхода с известными результатами.

7. Заключение. Полученные результаты позволяют сделать вывод, что в ходе проведенного исследования разработан аналитический аппарат, позволяющий получить вероятностную оценку результатов обработки изображений. Несмотря на то, что объектом исследования являлись результаты разливов нефтепродуктов в акваториях морей и океанов, разработанный аналитический аппарат может быть применен и в других областях науки и техники, связанных с обработкой кадров фото и видеоизображений.

В работе обосновано понятие аномалий, под которыми, в широком аспекте, авторы понимают элементы фона (фрагменты) графического изображения, возникающие в результате внешних факторов, в частности, последствий разливов нефтепродуктов.

Это позволило разработать подход к формированию первичных и вторичных векторов признаков обрабатываемых изображений на основе гистограмм распределения яркости, с последующей их кратномасштабной обработкой. Выбор кратномасштабной обработки в качестве декоррелирующего преобразования обусловлен высокой зависимостью дисперсии векторов признаков, формируемых на основе гистограмм распределения яркости от вариативности фона изображений, относящихся к одному и тому же альтернативному классу распознаваемых объектов.

Это позволило построить классификатор, работающий с компактными данными, характеризующими изображения.

В работе обоснован выбор вейвлета Гаусса 1-го порядка в декоррелирующей обработке векторов признаков. И хотя его эффективность доказана только для частного случая, полученные результаты, по аналогии с рекомендациями [24, 25] могут быть обобщены на более широкий класс изображений, при условии соответствия закона распределения их амплитудных значений яркости, с представленными примерами изображений.

Состоятельность предложений основана на численных результатах, характеризующих вероятностную оценку, которые получили подтверждение в эксперименте по обнаружению аномалий на 252 фрагментах изображений. Средняя вероятность достоверного принятия решения по полученным результатам составляет 0,95. Это обеспечивается за счет использования коэффициента повышения различий, значение которого целесообразно каждый раз уточнять перед проведением расчетов. Практическую направленность полученных результатов исследований авторы связывают

с их применением в решении задач поиска разливов нефтепродуктов по результатам обработки изображений.

Литература

1. Козловский А.В. Распараллеливание обработки информации при формировании составных изображений // Известия ЮФУ. Технические науки. 2025. №1(243). С. 92–103. DOI: 10.18522/2311-3103-2025-1-92-103.
2. Ушенкин В.А. Метод высокоточной обработки топографических интерферометрических изображений с привлечением низкодетальной стереофотограмметрической информации от оптико-электронных систем ДЗЗ // Цифровая обработка сигналов. 2025. №1. С. 59–66.
3. Хомяков О.О., Панищев В.С., Титов В.С., Ватутин Э.И. Математическая модель и параллельный алгоритм обработки изображений, содержащих символьную информацию // Труды МАИ. 2024. №137. С. 1–25.
4. Копейкин Р.Е., Перов А.Ю., Соловьев М.А. Алгоритмы поляризационной селекции для обработки информации в изображениях, полученных с помощью радара с синтезированной апертурой // Научно-технический вестник Поволжья. 2023. №12. С. 301–303.
5. Хомколов И.В., Медиевский А.В., Зотин А.Г., Симонов К.В., Кругляков А.С. Информации алгоритмическое обеспечение обработки и анализа изображений медицинского эксперимента // Информатизация и связь. 2023. №3. С. 35–42. DOI: 10.34219/2078-8320-2023-14-3-35-42.
6. Дворников С.В., Васильева Д.В. Повышение достоверности выявления аномалий на изображениях при формировании их векторов признаков в базах вейвлетов // Информатика и автоматизация. 2024. Т. 23. №6. С. 1698–1729. DOI: 10.15622/ia.23.6.5.
7. Abbasov I.B. Image Recognition in Agriculture and Landscape Protection // International Journal of Science and Research. 2020. vol. 9. no. 12. pp. 757–763. DOI: 10.21275/SR201212144831.
8. Васильева Д.В., Дворников С.В. Структуризация первичных признаков изображений систем мониторинга окружающей среды // Радиотехника. 2024. Т. 88. №8. С. 5–17. DOI: 10.18127/j00338486-202408-01.
9. Пахлян И.А., Омелянюк М.В. Разработка технических и технологических решений для очистки акваторий от разлива нефтепродуктов // Нефтяное хозяйство. 2025. №8. С. 94–97. DOI: 10.24887/0028-2448-2025-8-94-97.
10. Маценко С.В., Блиновская Я.Ю. Показатели эффективности мероприятий по ликвидации разливов нефти и нефтепродуктов на морских акваториях: организационные и технологические аспекты // Защита окружающей среды в нефтегазовом комплексе. 2023. №2(311). С. 5–11.
11. Vasilyeva D.V., Dvornikov S.V., Yakushenko S.A., Dvornikov S.S. Automation of detection procedures based on the results of processing images from video surveillance systems // Collection of abstracts of reports of the III International Forum “Mathematical methods and models in high-tech production”. 2023. 157–158.
12. Петрова Е.Г. Чрезвычайные ситуации с аварийным выбросом опасных химических веществ // Экологические системы и приборы. 2023. №5. С. 47–54. DOI: 10.25791/esip.5.2023.1372.
13. Подрезов Р.В., Райфельд М.А. Непараметрический метод определения числа классов в задаче сегментации изображений // Автотметрия. 2020. Т. 56. №3. С. 81–90. DOI: 10.15372/AUT20200309.
14. Андриянов Н.А., Гаврилина Ю.Н. Исследование алгоритма обнаружения детерминированных аномалий на сложных изображениях с помощью дважды

- стохастической модели // Ural Radio Engineering Journal. 2020. Т. 4. №1. С. 18–32. DOI: 10.15826/urej.2020.4.1.002.
15. Li J., Li X., Li H., et al. Fabrication of the Cu/AgCuTi/Nb composite for superconducting radio-frequency material under extreme service conditions based on electroplating additive manufacturing // Materials & Design. 2024. vol. 244. 113220 p. DOI: 10.1016/j.matdes.2024.113220.
16. Белов А.М., Денисова А.Ю. Классификация изображений ДЗЗ с использованием алгоритма комплексирования данных различных сенсоров // Компьютерная оптика. 2020. Т. 44. №4. С. 627–635. DOI: 10.18287/2412-6179-CO-735.
17. Васильева Д.В., Дворников С.В., Якушенко С.А., Дворников С.С. Автоматизация процедур обнаружения лесных пожаров по результатам обработки видео // Вестник Санкт-Петербургского университета государственной противопожарной службы МЧС России. 2023. №4. С. 47–58. DOI: 10.61260/2218-130X-2024-2023-4-47-58.
18. Сурин В.А. Об обработке зашумленных контрастных изображений // Вестник Южно-Уральского государственного университета. 2021. Т. 13. №1. С. 14–21. DOI: 10.14529/mmph210102.
19. Велигоша А.В., Малышко Н.Н., Струков Р.И. Применение искусственных нейронных сетей для снижения избыточности дискретного вейвлет-преобразования изображений // Теория и техника радиосвязи. 2020. №2. С. 5–12.
20. Чебачев В.О. Обработка сигналов в системах радиочастотной идентификации с помощью декоррелирующих преобразований // Вопросы радиоэлектроники. 2016. №9. С. 35–40.
21. Булатов Ю.Н. Теорема о норме сингулярных J-псевдодифференциальных операторов Киприянова-Катрахова // Вестник Воронежского государственного университета. 2025. №2. С. 38–48.
22. Осанов В.А. Сравнительный анализ методов декорреляции сетевого трафика // Вестник Рязанского государственного радиотехнического университета. 2025. №92. С. 25–38. DOI: 10.21667/1995-4565-2025-92-25-38.
23. Семенов В.И. Сравнение алгоритма кратномасштабного анализа изображений в частотной области с алгоритмом Малла // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2022. №59. С. 73–82. DOI: 10.17223/19988605/59/8.
24. Sheikh H.R., Bovik A.C. Image information and visual quality // IEEE Transactions on Image Processing. 2006. vol. 15. no. 2. pp. 430–444. DOI: 10.1109/tip.2005.859378.
25. Bisgard J. Analysis and Linear Algebra: The Singular Value Decomposition and Applications / Student Mathematical Library // AMS. 2021. 217 p.
26. Дворников С.В., Дворников С.С., Коноплев М.А. Алгоритм распознавания сигналов радиосвязи на основе симметрических матриц // Информационные технологии. 2010. №9. С. 75–77.
27. Harvey Mudd College. Karhunen-Loeve Transformation. URL: <https://pages.hmc.edu/ruye/MachineLearning/lectures/ch8/node4.html> (дата обращения: 02.10.2025).
28. Ahmed N., Natarajan T., Rao K.R. Discrete Cosine Transform // IEEE Transactions on Computers. 1974. vol. 23. no. 1. pp. 90–93. DOI: 10.1109/T-C.1974.223784.
29. Loeffler C., Ligtenberg A., Moschytz G.S. Practical Fast 1-D DCT Algorithms with 11 Multiplications // Proceedings of the International Conference on Acoustics, Speech, and Signal Processing (ICASSP). 1989. pp. 988–991.
30. Дворников С.В., Степных Д.В., Дворников А.С., Букарева А.П. Формирование векторов признаков сигналов из вейвлет-коэффициентов их фреймовых преобразований // Информационные технологии. 2013. №5. С. 46–49.

31. Flores-Soriano M. Solar radio bursts impact on the International GNSS Service Network during Solar Cycle 24 // *Journal of Space Weather and Space Climate*. 2024. DOI: 10.1051/swsc/2024034.
32. Васильева Д.В. Исследование чувствительности векторов признаков, сформированных на основе кратномасштабных преобразований обрабатываемых изображений // *Известия высших учебных заведений России. Радиоэлектроника*. 2024. Т. 27. №3. С. 20–29. DOI: 10.32603/1993-8985-2024-27-3-20-29.
33. Singh U., Dua A., Kumar N., Guizani M. QoS Aware Uplink Scheduling for M2M Communication in LTE/LTE-A Network: A Game Theoretic Approach // *IEEE Transactions on Vehicular Technology*. 2022. vol. 71. no. 4. pp. 4156–4170. DOI: 10.1109/TVT.2021.3132535.
34. Сай С.В., Зинкевич А.В., Фомина Е.С. Сравнение дискретного косинус и вейвлет-преобразований в системах сжатия RAW-изображений // *Компьютерная оптика*. 2022. Т. 46. №6. С. 929–938. DOI: 10.18287/2412-6179-СО-1094.
35. Велигоша А.В., Малышко Н.Н., Струков Р.И. Применение искусственных нейронных сетей для снижения избыточности дискретного вейвлет-преобразования изображений // *Теория и техника радиосвязи*. 2020. №2. С. 5–12.
36. Гришпенцев А.Ю., Коровкин Н.В., Островский Д.П. Вейвлеты Эрмита-Гаусса: синтез дискретных форм и исследование свойств // *Научно-технический вестник информационных технологий, механики и оптики*. 2025. Т. 25. №4. С. 789–796. DOI: 10.17586/2226-1494-2025-25-4-789-796.
37. Chui C.K. An Introduction to Wavelets / Wavelet Analysis & Its Applications // San Diego: Academic Press. 1992. 266 p.
38. Семенов В.И., Чумаров С.Г. От конструирования вейвлетов на основе производных функции Гаусса к синтезу фильтров с конечной импульсной характеристикой // *Научно-технический вестник информационных технологий, механики и оптики*. 2024. Т. 24. №2. С. 306–313. DOI: 10.17586/2226-1494-2024-24-2-306-313.
39. Беляев А.А., Кононов Д.П., Кудрин А.М. Исследование выбора материнской вейвлет-функции при вибродиагностике тепловозных двигателей // *Известия Петербургского университета путей сообщения*. 2025. Т. 22. №2. С. 290–299. DOI: 10.20295/1815-588X-2025-2-290-299.
40. Васильева Д.В., Дворников С.С., Толстуха Ю.Е., Обрезков П.С., Дворников С.В. Формирование векторов признаков для систем видеонаблюдения // *Вопросы радиоэлектроники*. 2023. №4. С. 62–68.
41. Dvornikov S.S., Zheglov K.D., Dvornikov S.V. SSB signals with controlled pilot level // *T-Comm*. 2023. vol. 17. no. 3. pp. 41–47. DOI: 10.36724/2072-8735-2023-17-3-41-47.
42. Jiao Z., Jia G., Cai Y. A new approach to oil spill detection that combines deep learning with unmanned aerial vehicles // *Computers & Industrial Engineering*. 2019. vol. 135. pp. 1300–1311.
43. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. pp. 770–778. DOI: 10.1109/CVPR.2016.90.
44. Howard A.G., Zhu M., Chen B., et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications // *arXiv preprint arXiv:1704.04861*. 2017.
45. Venkatesan R., Li B. Convolutional Neural Networks in Visual Computing: A Concise Guide // Boca Raton: CRC Press. 2017. 186 p.
46. Orfanidis G., Ioannidis K., Avgerinakis K., et al. A Deep Neural Network for Oil Spill Semantic Segmentation in Sar Images // *Proceedings of 25th IEEE International Conference on Image Processing (ICIP)*. 2018. pp. 3773–3777. DOI: 10.1109/ICIP.2018.8451113.

Дворников Сергей Викторович — д-р техн. наук, профессор, кафедра конструирования и технологий электронных и лазерных средств института радиотехники и инфокоммуникационных технологий, Федеральное государственное автономное образовательное учреждение высшего образования «Санкт-Петербургский государственный университет аэрокосмического приборостроения» (ФГАОУ ВО ГУАП); профессор, кафедра радиосвязи, Военная академия орденов Жукова и Ленина Краснознамённая академия связи имени Маршала Советского Союза С.М. Будённого (ВАС им. С.М. Будённого). Область научных интересов: построение помехозащищенных систем радиосвязи, формирование и обработка сигналов сложных структур. Число научных публикаций — 700. practicdsv@yandex.ru; ул. Большая Морская, 67, 190000, Санкт-Петербург, Россия; р.т.: +7(812)247-9400.

Васильева Дина Владимировна — старший преподаватель, кафедра радиотехнических систем института радиотехники и инфокоммуникационных технологий, Федеральное государственное автономное образовательное учреждение высшего образования «Санкт-Петербургский государственный университет аэрокосмического приборостроения» (ФГАОУ ВО ГУАП). Область научных интересов: цифровая обработка сигналов. Число научных публикаций — 61. dolli.dina@mail.ru; ул. Большая Морская, 67, 190000, Санкт-Петербург, Россия; р.т.: +7(931)385-9181.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда (проект № 24-79-10259).

S. DVORNIKOV, D. VASILIEVA

OIL SPILL IMAGE RECOGNITION BASED ON MULTIPLE-SCALE PROCESSING OF BRIGHTNESS DISTRIBUTION HISTOGRAMS

Dvornikov S., Vasilieva D. Oil Spill Image Recognition Based on Multiple-Scale Processing of Brightness Distribution Histograms.

Abstract. The problem of detecting anomalies in processed images acquired from visual monitoring equipment becomes particularly relevant in the context of ecological monitoring of the world ocean's water areas, specifically when searching for the consequences of technogenic catastrophes caused by oil spills. In the present study, anomalies are understood as image fragments characterizing oil product spills. The subject of the research is defined by elements of pattern recognition theory, according to which the processed images are represented as feature vectors. The rationale for selecting histograms characterizing the brightness bit distributions of the processed images, which are used as primary feature vectors, is substantiated. It is established that the high variability of the background of water surface images leads to significant variance in the feature vectors formed on the basis of brightness distribution histograms, even for a single common class of recognition objects. Therefore, it is proposed to subject the primary feature vectors to decorrelating processing based on wavelet transforms. Types of wavelet transforms and various types of generating functions are considered, among which the rationale for selecting the first-order Gaussian wavelet is provided, as it ensures the smallest differences between the feature vectors of the processed images characterizing the same class. An approach to the formation of secondary recognition features is proposed by averaging the components of multiscale transformation matrices of image brightness distribution histograms along the axis of their shift parameter. The rationale for transitioning to the selection of a redundant number of decomposition scales in wavelet transforms when forming secondary feature vectors is substantiated. The results of the conducted experiment are demonstrated, confirming the validity of such a transition. Test and reference images used in the experiment are presented, as well as the primary and secondary feature vectors formed on their basis. Numerical results characterizing the obtained estimate of differences between feature vectors of both the same class and alternative classes are provided. A probabilistic assessment of the anomaly recognition results on the processed images is presented. The rationale for using the coefficient of estimating differences between feature vectors in the developed formula for the probability of correct anomaly detection in the processed images is substantiated. Graphs characterizing the value of the probabilistic estimate as a function of the ratio of anomaly size to the total frame area for various values of the coefficient enhancing the differences between feature vectors are presented.

Keywords: image anomalies, oil product spills, feature vectors, recognizable image classes, histograms of image brightness distribution.

References

1. Kozlovsky A.V. [Parallelization of information processing in the formation of composite images]. *Izvestiya YuFU. Tekhnicheskie nauki – Izvestiya SFedU. Engineering Sciences*. 2025. no. 1(243), pp. 92–103. DOI: 10.18522/2311-3103-2025-1-92-103. (In Russ.).
2. Ushenkin V.A. [Method for high-precision processing of topographic interferometric images using low-resolution stereophotogrammetric information from

- optical-electronic remote sensing systems.]. *Cifrovaya obrabotka signalov – Digital Signal Processing*. 2025. no. 1. pp. 59–66. (In Russ.).
3. Khomyakov O.O., Panishchev V.S., Titov V.S., Vatutin E.I. [Mathematical model and parallel algorithm for processing images containing character information.]. *Trudy MAI – Proceedings of MAI*. 2024. no. 137. pp. 1–25. (In Russ.).
4. Kopeykin R.E., Perov A.Y., Solovyov M.A. [Polarization selection algorithms for processing information in images obtained using synthetic aperture radar.]. *Nauchno-texnicheskij vestnik Povolzh'ya – Scientific and Technical Volga region Bulletin*. 2023. no. 12. pp. 301–303. (In Russ.).
5. Khomkolov I.V., Medievsky A.V., Zotin A.G., Simonov K.V., Kruglyakov A.S. [Information and algorithmic support for processing and analyzing images in a medical experiment.]. *Informatizatsiya i svyaz – Informatization and Communication*. 2023. no. 3. pp. 35–42. DOI: 10.34219/2078-8320-2023-14-3-35-42. (In Russ.).
6. Dvornikov S., Vasilyeva D. [Increase of Reliability of Anomalies Detection on Images at Formation of Their Feature Vectors in Wavelet Bases]. *Informatika i avtomatizatsiya – Informatics and Automation*. 2024. vol. 23. no. 6. pp. 1698–1729. DOI: 10.15622/ia.23.6.5. (In Russ.).
7. Abbasov I.B. Image Recognition in Agriculture and Landscape Protection. *International Journal of Science and Research*. 2020. vol. 9. no. 12. pp. 757–763. DOI: 10.21275/SR201212144831.
8. Vasilyeva D.V., Dvornikov S.V. [Structuring Primary Image Features of Environmental Monitoring Systems]. *Radiotekhnika – Radio engineering*. 2024. vol. 88. no. 8. pp. 5–17. DOI: 10.18127/j00338486-202408-01. (In Russ.).
9. Pakhlyan I.A., Omelyanyuk M.V. [Development of technical and technological solutions for cleaning water areas from oil spills]. *Neftyanoe xozyajstvo – The oil industry*. 2025. no. 8. pp. 94–97. DOI: 10.24887/0028-2448-2025-8-94-97. (In Russ.).
10. Matsenko S.V., Blinovskaya Y.Y. [Indicators of the effectiveness of measures to eliminate oil and petroleum product spills in marine areas: organizational and technological aspects.]. *Zashhita okruzhayushhej sredy v neftegazovom komplekse – Environmental Protection in Oil and Gas Complex*. 2023. no. 2(311). pp. 5–11. (In Russ.).
11. Vasilyeva D.V., Dvornikov S.V., Yakushenko S.A., Dvornikov S.S. Automation of detection procedures based on the results of processing images from video surveillance systems. Collection of abstracts of reports of the III International Forum “Mathematical methods and models in high-tech production”. 2023. 157–158.
12. Petrova E.G. [Emergency situations involving the accidental release of hazardous chemicals]. *E'kologicheskie sistemy i pribory – Ecological systems and devices*. 2023. no. 5. pp. 47–54. DOI: 10.25791/esip.5.2023.1372. (In Russ.).
13. Podrezov R.V., Raifeld M.A. [Nonparametric method for determining the number of classes in the image segmentation problem.]. *Avtometriya – Autometry*. 2020. vol. 56. no. 3. pp. 81–90. DOI: 10.15372/AUT20200309. (In Russ.).
14. Andriyanov N.A., Gavrilina Yu.N. [Research of an algorithm for detecting deterministic anomalies in complex images using a doubly stochastic model.]. *Ural'skij radiotekhnicheskij zhurnal – Ural Radio Engineering Journal*. 2020. vol. 4. no. 1. pp. 18–32. DOI: 10.15826/urej.2020.4.1.002. (In Russ.).
15. Li J., Li X., Li H., et al. Fabrication of the Cu/AgCuTi/Nb composite for superconducting radio-frequency material under extreme service conditions based on electroplating additive manufacturing. *Materials & Design*. 2024. vol. 244. 113220 p. DOI: 10.1016/j.matdes.2024.113220.
16. Belov A.M., Denisova A.Y. [Classification of remote sensing images using an algorithm for combining data from various sensors.]. *Komp'yuternaya optika – Computer Optics*. 2020. vol. 44. no. 4. pp. 627–635. DOI: 10.18287/2412-6179-CO-735. (In Russ.).

17. Vasilyeva D.V., Dvornikov S.V., Yakushenko S.A., Dvornikov S.S. [Automation of Forest Fire Detection Procedures Based on Video Processing Results]. *Vestnik Sankt-Peterburgskogo universiteta gosudarstvennoj protivopozharnoj sluzhby* MChS Rossii – Bulletin of the Saint Petersburg University of the State Fire Service of the Ministry of Emergency Situations of Russia. 2023. no. 4. pp. 47–58. DOI: 10.61260/2218-130X-2023-4-47-58. (In Russ.).
18. Surin V.A. [On the Processing of Noisy Contrast Images]. *Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta* – Bulletin of the South Ural State University. 2021. vol. 13. no. 1. pp. 14–21. DOI: 10.14529/mmph210102. (In Russ.).
19. Veligosha A.V., Malyshev N.N., Strukov R.I. [Application of artificial neural networks to reduce the redundancy of the discrete wavelet transform of images.]. *Teoriya i tekhnika radiosvyazi* – Radio Communication Theory and Equipment. 2020. no. 2. pp. 5–12. (In Russ.).
20. Chebachiev V.O. [Signal Processing in Radio-Frequency Identification Systems Using Decorrelating Transformations]. *Voprosy`lektroniki* – Questions of radio electronics. 2016. no. 9. pp. 35–40. (In Russ.).
21. Bulatov Y.N. [Theorem on the norm of singular J-pseudodifferential operators by Kupriyanov–Katrakhov]. *Vestnik Voronezhskogo gosudarstvennogo universiteta* – Bulletin of Voronezh State University. 2025. no. 2. pp. 38–48. (In Russ.).
22. Osanov V.A. [Comparative analysis of network traffic decorrelation methods]. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta* – Vestnik of Ryazan State Radio Engineering University. 2025. no. 92. pp. 25–38. DOI: 10.21667/1995-4565-2025-92-25-38. (In Russ.).
23. Semenov V.I. [Comparison of the multi-scale image analysis algorithm in the frequency domain with Mallat's algorithm]. *Tomsk State University Journal of Control and Computer Science* – Vestnik Tomskogo gosudarstvennogo universiteta. *Upravlenie, vychislitel'naya tekhnika i informatika*. 2022. no. 59. pp. 73–82. DOI: 10.17223/19988605/59/8. (In Russ.).
24. Sheikh H.R., Bovik A.C. Image information and visual quality. *IEEE Transactions on Image Processing*. 2006. vol. 15. no. 2. pp. 430–444. DOI: 10.1109/tip.2005.859378.
25. Bisgard J. *Analysis and Linear Algebra: The Singular Value Decomposition and Applications* (Series: Student Mathematical Library). AMS. 2021. 217 p.
26. Dvornikov S.V., Dvornikov S.S., Konoplev M.A. [An algorithm for recognizing radio communication signals based on symmetric matrices.]. *Informacionny`e tekhnologii* – Information technology. 2010. no. 9. pp. 75–77. (In Russ.).
27. Harvey Mudd College. Karhunen-Loeve Transformation. Available at: <https://pages.hmc.edu/ruye/MachineLearning/lectures/ch8/node4.html> (accessed 02.10.2025). (In Russ.).
28. Ahmed N., Natarajan T., Rao K.R. Discrete Cosine Transform. *IEEE Transactions on Computers*. 1974. vol. 23. no. 1. pp. 90–93. DOI: 10.1109/T-C.1974.223784.
29. Loeffler C., Ligtenberg A., Moschytz G.S. Practical Fast 1-D DCT Algorithms with 11 Multiplications. *Proceedings of the International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*. 1989. pp. 988–991.
30. Dvornikov S.V., Stepyanin D.V., Dvornikov A.S., Bukareva A.P. [Formation of signal feature vectors from wavelet coefficients of their frame transforms]. *Informacionny`e tekhnologii* – Information technology. 2013. no. 5. pp. 46–49. (In Russ.).
31. Flores-Soriano M. Solar radio bursts impact on the International GNSS Service Network during Solar Cycle 24. *Journal of Space Weather and Space Climate*. 2024. DOI: 10.1051/swsc/2024034.
32. Vasilyeva D.V. [Study of the sensitivity of feature vectors formed based on multi-scale transformations of the processed images.]. *Izvestiya vysshix uchebny`x zavedenij*

- Rossii. Radioelektronika – Journal of the Russian universities. Radioelectronics. 2024. vol. 27. no. 3. pp. 20–29. DOI: 10.32603/1993-8985-2024-27-3-20-29. (In Russ.).
33. Singh U., Dua A., Kumar N., Guizani M. QoS Aware Uplink Scheduling for M2M Communication in LTE/LTE-A Network: A Game Theoretic Approach. IEEE Transactions on Vehicular Technology. 2022. vol. 71. no. 4. pp. 4156–4170. DOI: 10.1109/TVT.2021.3132535.
34. Sai S.V., Zinkevich A.V., Fomina E.S. [Comparison of Discrete Cosine and Wavelet Transforms in RAW Image Compression Systems]. Computer Optics – Komp'yuternaya optika. 2022. vol. 46. no. 6. pp. 929–938. DOI: 10.18287/2412-6179-CO-1094. (In Russ.).
35. Veligosha A.V., Malyshko N.N., Strukov R.I. [Application of artificial neural networks to reduce the redundancy of the discrete wavelet transform of images.]. Teoriya i tekhnika radiosvyazi – Radio Communication Theory and Equipment. 2020. no. 2. pp. 5–12. (In Russ.).
36. Grishentsev A.Y., Korovkin N.V., Ostrovsky D.P. [Hermite–Gauss wavelets: synthesis of discrete forms and study of properties]. Nauchno-tekhnicheskij vestnik informacionny'x tekhnologij, mexaniki i optiki – Scientific and Technical Journal of Information Technologies, Mechanics and Optics. 2025. vol. 25. no. 4. pp. 789–796. DOI: 10.17586/2226-1494-2025-25-4-789-796. (In Russ.).
37. Chui C.K. An Introduction to Wavelets (Series: Wavelet Analysis & Its Applications). San Diego: Academic Press. 1992. 266 p.
38. Semenov V.I., Chumarov S.G. [From the design of wavelets based on the derivatives of the Gaussian function to the synthesis of filters with finite impulse response.]. Nauchno-tekhnicheskij vestnik informacionny'x tekhnologij, mexaniki i optiki – Scientific and Technical Journal of Information Technologies, Mechanics and Optics. 2024. vol. 24. no. 2. pp. 306–313. DOI: 10.17586/2226-1494-2024-24-2-306-313. (In Russ.).
39. Belyaev A.A., Kononov D.P., Kudrin A.M. [Research into the choice of the mother wavelet function in vibration diagnostics of diesel locomotive engines.]. Izvestiya Peterburgskogo universiteta putej soobshheniya – Proceedings of Petersburg Transport University. 2025. vol. 22. no. 2. pp. 290–299. DOI: 10.20295/1815-588X-2025-2-290-299. (In Russ.).
40. Vasilyeva D.V., Dvornikov S.S., Tolstukha Y.E., Obrezkov P.S., Dvornikov S.V. [Feature vector generation for video surveillance systems]. Voprosy` radioelektroniki – Questions of radio electronics. 2023. no. 4. pp. 62–68. (In Russ.).
41. Dvornikov S.S., Zheglov K.D., Dvornikov S.V. SSB signals with controlled pilot level. T-Comm. 2023. vol. 17. no. 3. pp. 41–47. DOI: 10.36724/2072-8735-2023-17-3-41-47.
42. Jiao Z., Jia G., Cai Y. A new approach to oil spill detection that combines deep learning with unmanned aerial vehicles. Computers & Industrial Engineering. 2019. vol. 135. pp. 1300–1311.
43. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. pp. 770–778. DOI: 10.1109/CVPR.2016.90.
44. Howard A.G., Zhu M., Chen B., et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv preprint arXiv:1704.04861. 2017.
45. Venkatesan R., Li B. Convolutional Neural Networks in Visual Computing: A Concise Guide. Boca Raton: CRC Press. 2017. 186 p.
46. Orfanidis G., Ioannidis K., Aygerinakis K., et al. A Deep Neural Network for Oil Spill Semantic Segmentation in Sar Images. Proceedings of 25th IEEE International Conference on Image Processing (ICIP). 2018. pp. 3773–3777. DOI: 10.1109/ICIP.2018.8451113.

Dvornikov Sergei — Ph.D., Dr.Sci., Professor, Department of Design and Technology of Electronic and Laser Facilities of the Institute of Radio Engineering and Infocommunication Technologies, Federal State Autonomous Educational Institution of Higher Education Saint Petersburg University State University of Aerospace Instrumentation (GUAP Federal State Educational Institution of Higher Education); Professor, Department of Radio Communication, The Military Academy of the Orders of Zhukov and Lenin, the Red Banner Academy of Communications named after Marshal of the Soviet Union S.M. Budyonny (S.M. Budyonny Military Academy of Communications). Research interests: construction of interference-resistant radio communication systems, formation and processing of complex signal structures. The number of publications — 700. practicdsv@yandex.ru; 67, Bolshaya Morskaya St., 190000, St. Petersburg, Russia; office phone: +7(812)247-9400.

Vasilieva Dina — Senior lecturer, Department of Radio Engineering Systems at the Institute of Radio Engineering and Information and Communication Technologies, Federal State Autonomous Educational Institution of Higher Education Saint Petersburg University State University of Aerospace Instrumentation (GUAP Federal State Educational Institution of Higher Education). Research interests: digital signal processing. The number of publications — 61. dolli.dina@mail.ru; 67, Bolshaya Morskaya St., 190000, St. Petersburg, Russia; office phone: +7(931)385-9181.

Acknowledgements. This study was supported by a grant from the Russian Science Foundation (project no. 24-79-10259).