

С.В. ДВОРНИКОВ, Д.В. ВАСИЛЬЕВА
**ПОВЫШЕНИЕ ДОСТОВЕРНОСТИ ВЫЯВЛЕНИЯ АНОМАЛИЙ
НА ИЗОБРАЖЕНИЯХ ПРИ ФОРМИРОВАНИИ ИХ ВЕКТОРОВ
ПРИЗНАКОВ В БАЗИСАХ ВЕЙВЛЕТОВ**

Дворников С.В., Васильева Д.В. Повышение достоверности выявления аномалий на изображениях при формировании их векторов признаков в базисах вейвлетов.

Аннотация. Предложен способ обнаружения спасательных плотов и шлюпок в акватории морей и океанов после кораблекрушений, основанный на распознавании аномалий на обрабатываемых изображениях, что увеличивает вероятность распознавания объектов мониторинга. Обоснован подход к решению такой задачи. Представлена постановка задачи распознавания объектов с позиций бинарной классификации при обнаружении аномалий. Получено аналитическое выражение для алгоритма принятия решения. Рассмотрена возможность формализации матриц изображений в виде гистограмм распределений интенсивности цветности (яркости). Оценена контрастность признакового пространства на их основе. Предложено повысить контрастность признаковых пространств за счет вторичной обработки гистограмм распределений в базисе кратномасштабной вейвлет-декомпозиции. Рассмотрена возможность реализации вейвлет-преобразований на основе функций Хаара и вейвлетов Гаусса 1-го и 2-го порядков. Обоснован механизм формирования вторичных векторов признаков из трехмерных вейвлет-преобразований, путем усреднения их коэффициентов по оси временного сдвига. Показано, что при одинаковой размерности гистограмм распределения яркости с вновь формируемыми векторами признаков, последние обеспечивают более высокую контрастность признаковых пространств. Рекомендовано для формализации изображений в формате jpeg использовать вейвлет Гаусса 2-го порядка, обеспечивающий при прочих равных условиях большую величину различий для изображений, содержащих аномалии. Разработан подход к вероятностной оценке алгоритма автоматического распознавания изображений. Получено аналитическое выражение и обоснованы его составляющие элементы. Приведены графические зависимости вероятности правильного обнаружения (расознавания) аномалий, в зависимости от размеров по отношению к общей площади кадра и дисперсии подстилающего фона. Представлены результаты эксперимента по распознаванию изображений со спасательной шлюпкой в акватории океана. Определены направления дальнейших исследований.

Ключевые слова: распознавание изображений, векторы признаков, вейвлет-преобразование, контрастность признаковых пространств.

1. Введение. По данным ООН (https://en.m.wikipedia.org/wiki/List_of_shipwrecks_in_2023). Свободный доступ на 29.04.2024) только за последний год произошло 205 крупных кораблекрушений. Поэтому вопросы проведения аварийно-спасательных работ на воде занимают одно из приоритетных направлений в деятельности Министерства по чрезвычайным ситуациям [1]. В интересах поиска и спасения потерпевших кораблекрушение создаются специальные подразделения,

занимающиеся мониторингом водного пространства [2, 3], в том числе и с использованием беспилотной авиации [4, 5].

Поэтому одной из приоритетных задач является разработка эффективного научно-методического аппарата, позволяющего осуществлять первичную обработку видеоматериалов с целью обнаружения терпящих бедствие на воде.

В настоящее время для этих целей активно используют метод искусственного интеллекта [6, 7]. Однако успешность его применения во многом зависит от качества разработанных алгоритмов идентификации, как правило, базирующихся на элементах теории распознавания образов [8 – 10].

С учетом указанных обстоятельств, в настоящей статье представлен подход к распознаванию объектов с позиций выявления аномалий на обрабатываемых изображениях по отношению к эталонным описаниям. В частности, рассмотрены предложения по повышению контрастности векторов признаков идентифицируемых объектов, за счет их формирования в базисах вейвлет-преобразований [11 – 13].

2. Обоснование подхода к решению задачи распознавания.

В общем случае задачу поиска результатов последствий аварий водного транспорта и терпящих бедствие на воде, можно рассматривать с позиций обнаружения аномалий на изображениях, выявляемых в процессе последовательного анализа представляемых для обработки данных [14, 15]. Видеоданные с беспилотного носителя поступают на пост мониторинга, где оператор по результатам их визуального анализа принимает решение о наличии или отсутствии на изображении терпящих бедствие [16]. Но учитывая огромные водные территории, в пределах которых приходится вести поиск, такой подход становится достаточно трудоемким.

В настоящее время широкое применение получили два научных направления, связанных с решением задач обнаружения объектов по результатам обработки изображений.

Первый подход базируется на технологии компьютерного зрения, а в основе другого используются результаты статистической обработки параметров изображений.

Технологии машинного обучения – активно развивающееся научное направление, основанное на применении нейронных сетей. Его сущность базируется на последовательном уточнении исходных алгоритмов, по результатам обработки данных, как на этапе «обучения», так и в процессе работы [17].

Анализ результатов исследований, связанных со сложностью идентификаций различного рода аномалий на водной поверхности, представленных в [18 – 22], показал перспективность применения технологий на основе глубокого обучения нейронных сетей (англ. Deep Neural Networks – DNNs). Среди которых, наилучшие результаты по обнаружению аномалий на водных поверхностях обеспечивают сверточные нейронные сети (англ. CNNs).

По результатам изучения трудностей практической реализации технологий CNNs в рассматриваемой проблематике [21, 22] было установлено, что для обработки изображения одной из наиболее эффективных нейронных сетей SENet необходимо осуществить $5,8 \times 10^9$ вычислительных операций. При этом обеспечивается вероятность распознавания на уровне 0,965, но размер обрабатываемого изображения составляет всего лишь 224×224 пикселей.

Это связано с проблемой обучения сети, поскольку результаты и последствия бедствий на воде сложно конкретизировать и затем формализовать в виде поправочных коэффициентов в решающих алгоритмах. Данный вывод сделан в [18].

В свою очередь статистический подход к обработке параметров изображений, базируется на методе классической теории распознавания образов, разработанных К. Фукунагой [23]. Однако его непосредственное применение, в виду высокой вариативности водной поверхности, будет связано со значительными сложностями, что подтверждается результатами, представленными в [24, 25].

Но, несмотря на свою ограниченность [26], статистический подход позволяет реализовать алгоритмы классификации, основанные на выявлении аномалий более простым образом, чем это обеспечат методы машинного обучения.

При этом понятие аномалий будем рассматривать с позиций А. Zimek и Е. Schubert, которые в [27] определили данное явление как: «...редкие данные, события или наблюдения, которые вызывают подозрения ввиду их существенного отличия от большей части данных». То есть применительно к рассматриваемой тематике – это объекты на изображениях водных поверхностях, не характерных для акваторий морей и океанов в отсутствии бедствий на воде.

Но для обеспечения эффективности такого подхода необходима разработка соответствующего методического аппарата, позволяющего осуществить требуемую формализацию обрабатываемых изображений до уровня их машинного восприятия и компьютерной обработки [28].

Очевидно, что результатом такой формализации должна быть некая цифровая матрица или вектор числовых значений, которые соответствующим образом отображают содержание обрабатываемого изображения [29, 30]. Только в этом случае возможна реализация параметрического подхода к решению задач классификации с позиций теории распознавания образов.

Таким образом, формализация изображений до уровня данных, позволяющих проводить их цифровую обработку, является основополагающим моментом проводимого исследования.

С учетом рассмотренных моментов выбора подхода к решению задачи обнаружения аномалий в обрабатываемых изображениях, можно заключить, что применение методов искусственного интеллекта в данной ситуации связано с определенными сложностями. Поскольку исполнение такого подхода предполагает необходимость организации высокоскоростного трафика с беспилотной авиацией, находящейся на значительном удалении от центров мониторинга, и наличие дорогостоящего высокопроизводительного оборудования, для реализации алгоритмов идентификации, при том, что существующий уровень техники не в полной мере позволяет эффективно решать задачи такого уровня, в частности, по размерам обрабатываемых изображений.

Поэтому целесообразным видится переход к методам теории распознавания образов, основанных на параметрической обработке фрагментов фото и видео материалов. Однако такой переход предполагает разработку методического аппарата по формализации данных обрабатываемых изображений до уровня, позволяющего формировать на их основе векторы признаков [10]. А учитывая, что эффективность систем распознавания определяется контрастностью признакового пространства, основополагающим моментом является поиск подходов, позволяющих указанную контрастность повысить.

В настоящей статье под понятием контрастности будем понимать различия физических признаков, характеризующих объекты (в данном случае изображения), относящихся к альтернативным (распознаваемым) классам [4].

3. Постановка задачи распознавания объектов на изображениях. В терминах методов теории распознавания образов, задачу обнаружения новых объектов на обрабатываемых изображениях можно отнести к задачам классификации [31], согласно которой по результатам обработки каждое изображение относят к одному из альтернативных классов, определяющих признаковое пространство распознавания.

При этом каждый из альтернативных классов будет представлен совокупностью признаков, характеризующих объект, из которых формируются векторы признаков.

Наиболее просто такая задача решается для случая выявления аномалий на обрабатываемых изображениях. То есть когда определяют два альтернативных класса изображений: A_1 – класс изображений на которых отсутствуют аномалии; и A_2 – класс изображений, которые содержат аномалии.

В рамках проводимых исследований, под аномалиями будем понимать наличие на видео и фотоматериалах изображений, относящихся к последствиям происшествий и аварий на воде (обломки судов, спасательные средства, и т.д.).

С позиций методов теории распознавания образов каждый из альтернативных классов характеризуется своими признаками, которые могут быть представлены в виде векторов признаков:

2V_m – вектор признаков характеризующий класс A_2 ; и 1V_m – вектор признаков характеризующий класс A_1 . Здесь $m = 1, \dots, M$ – текущий параметр, определяющий номер и позицию конкретного признака в векторе признаков, размерностью M [28].

Учитывая возможную вариативность признаков, характеризующих классы A_1 и A_2 , для них формируют, так называемые эталонные описания, на основе которых создают эталонные векторы признаков этих классов.

Под эталонными описаниями будем понимать усредненные значения, характеризующие распознаваемый объект (изображение). Причем усреднения могут осуществляться как на уровне построения альтернативных пространств, так и на уровне формирования характеризующих их векторов.

Вместе с тем наличие векторов признаков позволяет свести задачу классификации обрабатываемых текущих изображений к процедурам сравнения их векторов признаков с векторами признаков эталонных описаний альтернативных классов. То есть вектор признаков текущего изображения 0V_m будет сравниваться с эталонными векторами признаков двух альтернативных классов A_1 и A_2 . Аналитически такая операция представляет собой алгебраическую разность между парами векторов 2V_m и 0V_m , и 1V_m и 0V_m , рассчитываемую как

$$d_{01(02)} = \frac{1}{M} \sum_{m=1}^M | {}^0V_m - {}^{1(2)}V_m |, \quad (1)$$

где d_{01} – абсолютная разность между вектором обрабатываемого изображения 0V_m и вектором 1V_m , эталонного описания класса A_1 . d_{02} – разность между вектором 0V_m и вектором 2V_m .

Заметим, что абсолютная разность d_{01} как раз и определяет контрастность признаков. Для бинарной системы классификации данное значение будет характеризовать и контрастность признакового пространства распознавания. Для многоальтернативных алгоритмов контрастность признакового пространства распознавания будет определяться наибольшими различиями между любыми двумя произвольными векторами признаков.

Тогда искомый алгоритм принятия решения о наличии аномалий может быть представлен в виде условия оценки знаковой функции:

$$\text{sign}(d_{01} - d_{02}) = \begin{cases} 0 > A_0 \in A_2; \\ 0 \leq A_0 \in A_1. \end{cases} \quad (2)$$

В этом случае алгоритм классификации, с учетом вычисления аналитического значения разности векторов между обрабатываемым изображением и векторами эталонных описаний альтернативных классов, может быть приведен к следующему виду [4, 10]:

$$d_{01(02)} = \frac{1}{M} \sum_{m=1}^M | {}^0V_m - {}^{1(2)}V_m | \left. \begin{array}{l} A_0 \in A_2 \\ > \\ \leq \\ A_0 \in A_1 \end{array} \right\} d_{01} \quad d_{02}. \quad (3)$$

В соответствии с алгоритмом (3) эффективность правильной классификации тем выше, чем выше контрастность между векторами 1V_m и 2V_m .

Согласно выражению (3) чем больше различия между векторами признаков, т.е. чем выше контрастность d_{01} , тем проще сделать правильный выбор в пользу того, или иного класса. Другими словами, высокая контрастность изначально обеспечит высокую достоверность верного решения в условиях мешающих факторов, приводящих к снижению различий между векторами признаков, вызванных, например, вариативностью водной поверхности в условиях отсутствия аномалий.

Следовательно, необходим поиск такого функционального базиса формирования векторов признаков, который при минимальном

различии между альтернативными классами, обеспечит максимальные различия между их векторами признаков, т.е. обеспечит наибольшую разность для алгоритма (3).

Поскольку эффективность распознавания напрямую зависит от физических различий между векторами признаков при прочих равных условиях, то, частную вербальную задачу исследования определим в следующей формулировке.

Из возможных подходов к формализации изображений необходимо выбрать тот, который обеспечит наибольшую контрастность, сформированных на его основе векторов признаков. В общем случае, между двумя любыми альтернативными классами.

Далее полагая, что подход к формализации изображения предполагает его декомпозицию в функциональном базисе до уровня числовых значений, то математически частную задачу исследования запишем в следующем виде:

$$F\{V_m\}_M \max_{\|A_1 - A_2\| \rightarrow \min} |{}^1V_m - {}^2V_m|. \quad (4)$$

Здесь оператор $F\{*\}$ – обозначение функционального базиса декомпозиции изображения.

Учитывая результаты, полученные в [12 – 15, 28], предлагается в качестве функционального базиса декомпозиции изображений использовать их кратномасштабные преобразования на основе вейвлетов.

Далее будем полагать, что в рамках практических приложений, формализация изображений должна позволить получать векторы признаков удобные для их последующей алгоритмической обработки.

При этом следует понимать, что в ходе классификации используются процедуры не фактического распознавания изображения, а выявления наличия на нем признаков последствий аварий и происшествий на воде.

4. Выбор базиса формализации изображений. В [32] представлены исследования, согласно которым переход от формата изображений RGB (англ. Red, Green, Blue), к формату GS (англ. Gray Scale) ведет к потере информации лишь для цветов имеющих одинаковую интенсивность освещенности.

Для дальнейшей обработки матриц предлагается использовать декоррелирующие преобразования на основе вейвлет-преобразований [33, 34]. Так как матрица полутонового изображения размером 800×600 будет содержать 480 тыс. значений.

Учитывая, что матрица изображения представляет собой набор дискретных значений, предлагается использовать дискретные формы вейвлет-преобразования (ДВП) [35, 36].

В общем случае, реализация ДВП представляет собой результат свертки входной реализации обрабатываемого процесса $x[n]$ и формирующего материнского вейвлета $\psi[n]$.

Физически, реализацию ДВП можно рассматривать как результат декомпозиции входного процесса путем последовательной ВЧ-фильтрации $h[2n - k]$, с целью получения детализирующих значений, определяемых как вейвлет-коэффициенты $y_{\text{ВЧ}}[n]$. И НЧ-фильтрации $g[2n - k]$, для формирования аппроксимирующих коэффициентов $y_{\text{НЧ}}[n]$.

$$y_{\text{НЧ}}[n] \sum_{k=0}^K x[k]g[2n - k]. \quad (5)$$

$$y_{\text{ВЧ}}[n] \sum_{k=0}^K x[k]h[2n - k]. \quad (6)$$

Фильтры, описываемые выражениями (5) и (6) получили название квадратурных зеркальных фильтров.

Последовательная реализация процедур, определяемая выражениями (5) и (6), формирует двумерную матрицу вейвлет-коэффициентов, определяемую как дискретное вейвлет-преобразование [37]. Таким образом, ДВП можно рассматривать как распределение энергии входной реализации обрабатываемого процесса в пространстве масштабных преобразований и временных сдвигов формирующих (порождающих) материнских вейвлетов.

Простейшим вейвлетом, используемым для формирования ДВП, является вейвлет- Хаара, описываемый выражением [36]:

$$\psi_x[n] = \begin{cases} 1, & 0 \leq n < 1/2; \\ -1, & 1/2 \leq n < 1; \\ 0, & n \notin [0, 1). \end{cases} \quad (7)$$

В соответствии с аналитической формой представления (7), элементы входной реализации группируются по 2. И для каждой группы вычисляется их сумма и разность. Указанная группировка осуществляется рекурсивно, с образованием нового уровня

масштабирования в пространстве временных сдвигов [37]. В результате получают 2^{k-1} уровней декомпозиций и одну общую сумму в виде ошибки (остатка) аппроксимации.

На рисунке 1 показано временное представление отцовского $\phi_X(n)$ и материнского $\psi_X(n)$ вейвлетов.

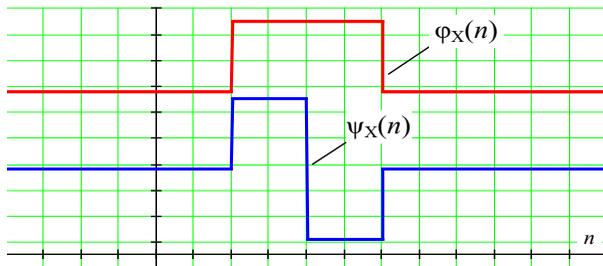


Рис. 1. Временное представление вейвлетов Хаара

Альтернативным решением для ДВП является вейвлет-преобразование на основе дискретных рядов непрерывного времени [38], формируемых, как правило, на основе вейвлетов Гаусса 1-го порядка $\psi_{\Gamma 1}[n]$:

$$\psi_{\Gamma 1}[n] = -n \exp(-n^2 / 2), \quad (8)$$

и 2-го порядка $\psi_{\Gamma 2}[n]$:

$$\psi_{\Gamma 2}[n] = (1 - n^2) \exp(-n^2 / 2). \quad (9)$$

На рисунке 2 демонстрируются временные структуры вейвлетов Гаусса $\psi_{\Gamma 1}[n]$ и $\psi_{\Gamma 2}[n]$.

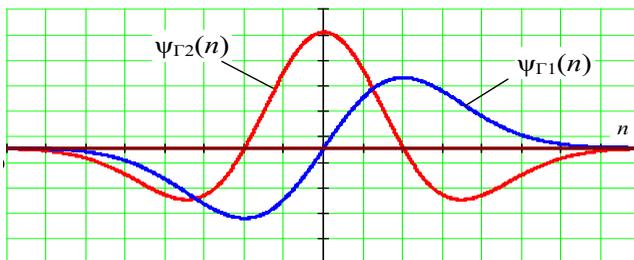


Рис. 2. Временное представление вейвлетов Гаусса

В настоящее время известны в теории и широко применяются на практике большое количество различных типов вейвлет-функций.

Выбор вейвлетов Гаусса на данном этапе обусловлен их хорошими аппроксимирующими свойствами, в приложении к обработке первичных векторов признаков изображений, формируемых в виде гистограмм распределения яркости из матриц полутоновых изображений [28]. В качестве примера представлен кадр изображения водной поверхности в формате *.jpg размером 600×800 пикселей, кодированных 8 битами.

В дальнейшем исследовании данное изображение определено как эталонное. Под понятием эталонного, будем понимать изображение, характеризующее наиболее типовой фон водной поверхности для условий проведения эксперимента (на практике – водная акватория до момента бедствий на воде).

В рамках настоящей статьи, изображение на рисунке 3 определяет класс A_1 , т.е. класс, определяющий изображения, а которых отсутствуют аномалии. Для примера, на рисунке 4 изображена матрица данных эталонного изображения.



Рис. 3. Изображение водной поверхности (эталонное)

Структуру матрицы, представленной на рисунке 4, определяют целочисленное значение пиксела в диапазоне от 0 до 255, с координатами по оси абсцисс и ординат, соответствующих ее размерности 600×800. Как уже отмечалось, размеры матрицы существенно затрудняют ее использование для непосредственного применения в алгоритмах распознавания. Поэтому в [10] предложено в качестве вектора признаков использовать гистограмму

распределения значений яркости пикселей, сформированную из матрицы изображений.

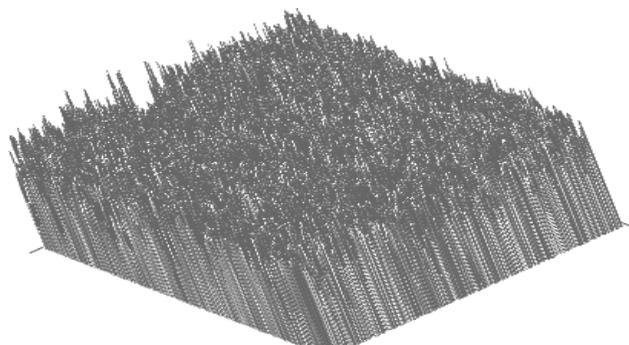


Рис. 4. Матрица данных эталонного изображения водной поверхности

На рисунке 5 демонстрируется гистограмма распределения яркости пикселей эталонного изображения.

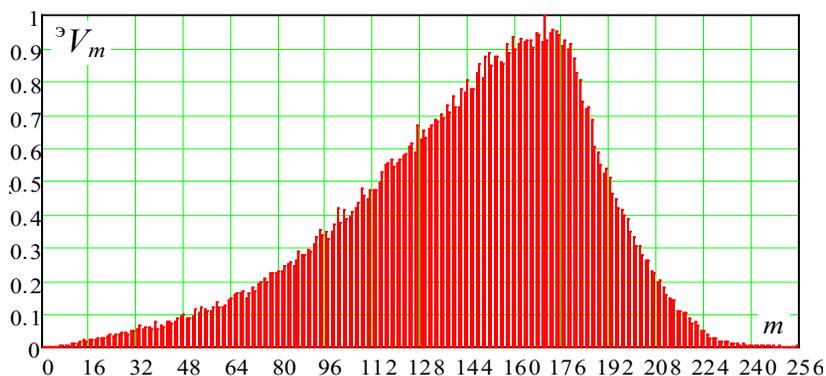


Рис. 5. Гистограмма распределения пикселей яркости эталонного изображения

Поскольку гистограмма распределения яркости представляет собой упорядоченный вектор, количество элементов которого всегда остается неизменным вне зависимости от размера и качества исходного изображения, то открывается возможность использования гистограммы в качестве векторов признаков распознавания.

Для оценки обоснованности такого подхода рассмотрим два кадра морской акватории (рисунок 6 и рисунок 7), на одном из которых изображена спасательная шлюпка.



Рис. 6. Шляпка на водной поверхности (изображение со шляпкой)

Отметим, что для эксперимента было отобрано 200 кадров с изображением морской поверхности в пределах одной акватории, полученных примерно в одно и то же время, и одних и тех же погодных условиях.



Рис. 7. Изображение водной поверхности (текущее)

На рисунке 8 и 9, соответственно показаны гистограммы распределения нормированных значений яркости, рассматриваемые в качестве векторов признаков, указанных изображений.

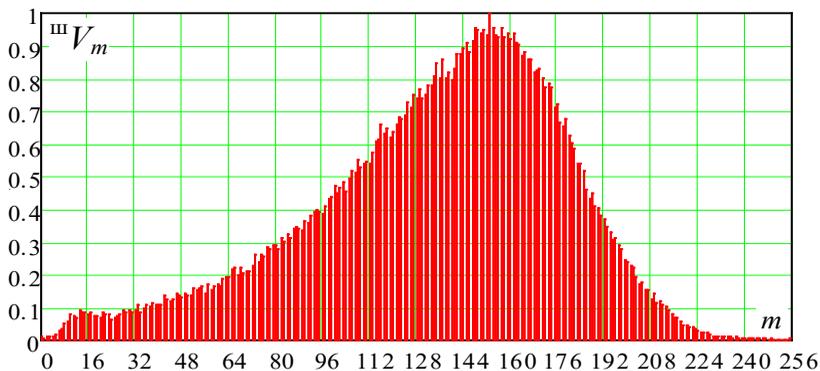


Рис. 8. Гистограмма распределения пикселей яркости изображения со шляпкой

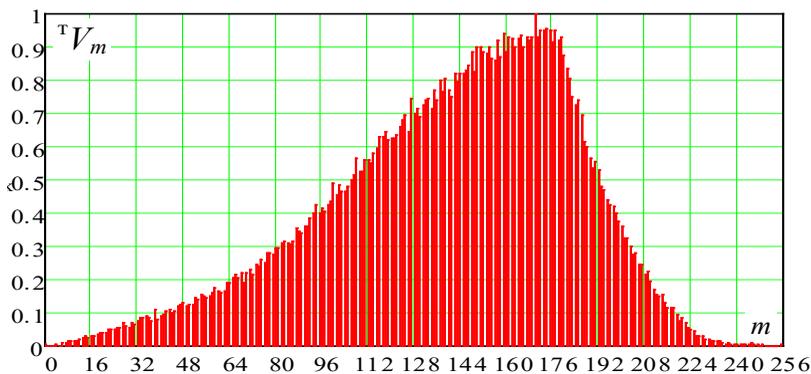


Рис. 9. Гистограмма распределения пикселей яркости текущего изображения

Далее, в соответствии с выражением (1), рассчитанная абсолютная разница между вектором обрабатываемого изображения ${}^{\text{т}}V_m$ и эталонного описания ${}^{\text{³}}V_m$ будет равна

$${}^{\text{т}}d = \frac{1}{256} \sum_{m=0}^{255} |{}^{\text{³}}V_m - {}^{\text{т}}V_m| = 0,03.$$

А между векторами ${}^{\text{³}}V_m$ и ${}^{\text{³}}V_m$, соответственно

$${}^{\text{т}}d = \frac{1}{256} \sum_{m=0}^{255} |{}^{\text{в}}V_m - {}^{\text{т}}V_m| = 0,068.$$

Полученный результат позволяет сделать заключение о потенциальной возможности использования распределения гистограмм пикселей яркости в качестве векторов признаков для распознавания изображений.

Однако более глубокий анализ исследуемых изображений показал, что положительный результат был обеспечен лишь благодаря более низкой дисперсии различий между векторами ${}^{\text{т}}V_m$ и ${}^{\text{в}}V_m$, (${}^{\text{т}}R = 5,36 \times 10^{-3}$) по отношению к дисперсии разности между векторами ${}^{\text{ш}}V_m$ и ${}^{\text{в}}V_m$ (${}^{\text{ш}}R = 7,04 \times 10^{-3}$).

В данном исследовании дисперсия различий разности между векторами рассчитывалась по следующей формуле

$${}^{\text{о}}R = \frac{1}{M-1} \times \left[\sum_{m=0}^{M-1} ({}^{\text{о}}V_m - {}^{\text{л}}V_m) - \frac{1}{M} \sum_{m=0}^{M-1} ({}^{\text{о}}V_m - {}^{\text{л}}V_m) \right]^2. \quad (10)$$

Низкая дисперсия различий между векторами ${}^{\text{т}}V_m$ и ${}^{\text{в}}V_m$ обусловлена тем, что волнение моря не превышает 1-2 баллов. Очевидно, что при более сильном волнении величина дисперсии, характеризующей различия векторов, возрастет, что существенно снизит вероятность правильной классификации.

Следовательно, необходим поиск подходов, позволяющих повысить контрастность признакового пространства распознавания, определяемого величиной различий векторов признаков, характеризующего его классов.

5. Результаты эксперимента. В соответствии с целевой установкой, для повышения контрастности признакового пространства предложено векторы признаков изображений строить на основе ДВП.

Матрицы дискретных значений вейвлет-преобразований для эталонного, текущего и изображения со шлюпкой на основе вейвлета Хаара представлены на рисунке 10.

Здесь ${}^{\text{в}}W_X$, ${}^{\text{т}}W_X$, ${}^{\text{ш}}W_X$ – ДВП эталонного, текущего и изображения со шлюпкой на основе вейвлета Хаара.

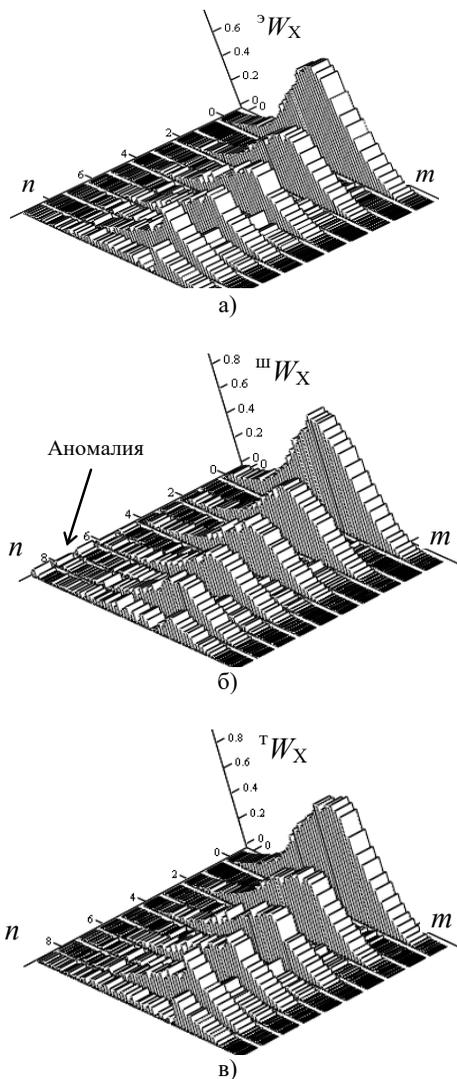
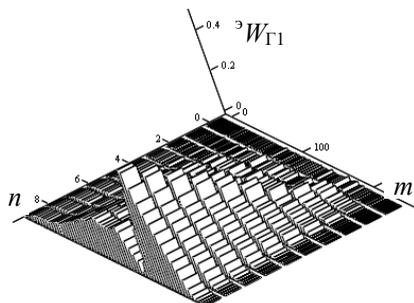
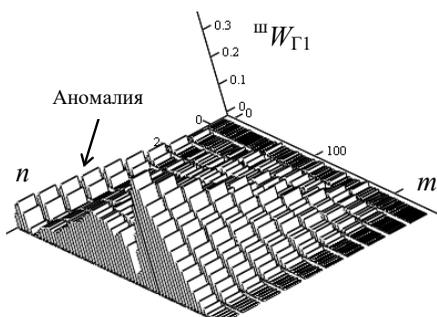


Рис. 10. а) матрицы эталонного изображения на основе вейвлета Хаара; б) матрицы изображения со шлюпкой на основе вейвлета Хаара; в) матрицы текущего изображения на основе вейвлета Хаара

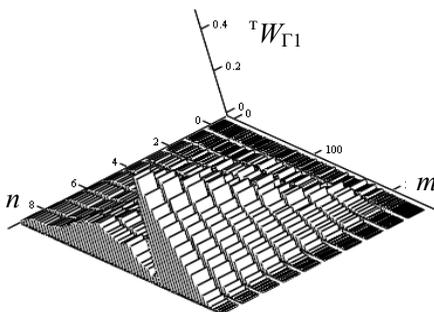
Матрицы дискретных значений вейвлет-преобразований для эталонного, текущего и изображения со шлюпкой на основе вейвлета Гаусса 1-го порядка представлены на рисунке 11.



а)



б)



в)

Рис. 11. а) матрицы эталонного изображения на основе вейвлета Гаусса 1-го порядка; б) матрицы изображения со шпюпкой на основе вейвлета Гаусса 1-го порядка; в) матрицы текущего изображения на основе вейвлета Гаусса 1-го порядка

Здесь ${}^{\circ}W_{Г1}$, ${}^{\tau}W_{Г1}$, ${}^{\text{ш}}W_{Г1}$ – ДВП эталонного изображения на основе Гаусса 1-го порядка.

Матрицы дискретных значений вейвлет-преобразований для эталонного, текущего и изображения со шляпкой на основе вейвлета Гаусса 2-го порядка представлены на рисунке 12.

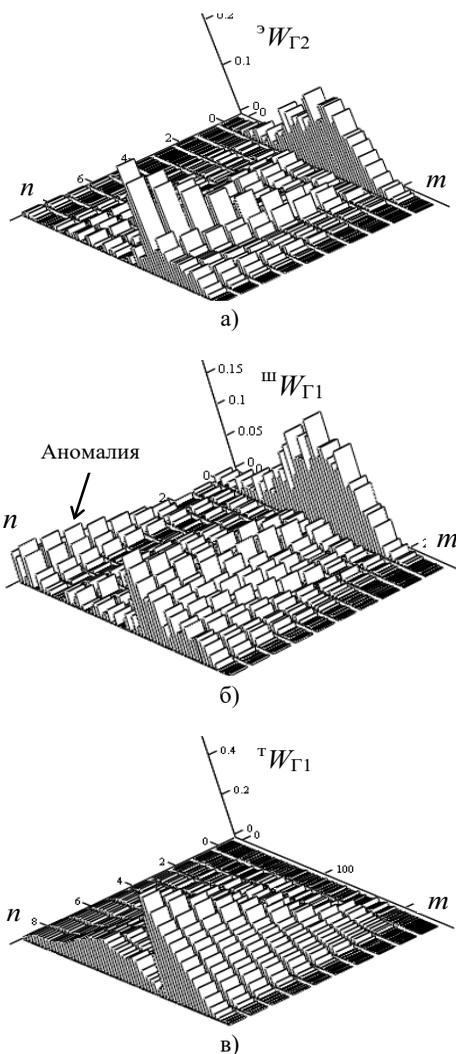


Рис. 12. а) матрицы эталонного изображения на основе вейвлета Гаусса 2-го порядка; б) матрицы изображения со шляпкой на основе вейвлета Гаусса 2-го порядка; в) матрицы текущего изображения на основе вейвлета Гаусса 2-го порядка

Здесь ${}^{\circ}W_{\Gamma_2}$, ${}^{\text{I}}W_{\Gamma_2}$, ${}^{\text{III}}W_{\Gamma_2}$ – ДВП эталонного изображения на основе Гаусса 2-го порядка.

Отметим, что даже визуальный анализ полученных изображений матриц ДВП позволяет сделать вывод о повышении контрастности признакового пространства.

Представленные на рисунках 9-11 матрицы ДВП для лучшей демонстрации построены с шагом сдвига равного четырем.

Так на матрицах ДВП, сформированных на основе вейвлетов Гаусса 1-го и 2-го порядков, для изображений шляпки отчетливо просматриваются характеризующие ее вейвлет-коэффициенты (на рисунках 10(б) и 11(б) указаны стрелкой).

Выявленные особенности позволяют выдвинуть гипотезу о повышении контрастности признаковых пространств изображений в результате их формирования на основе вейвлет-преобразований.

По результатам визуального анализа было принято заключение, что наиболее рельефно вейвлет-коэффициенты, характеризующие наличие шляпки, проявляются на матрице ДВП, построенной на основе вейвлета Гаусса 2-го порядка. Поэтому они были выбраны для построения векторов признаков.

На рисунке 13 представлены векторы признаков, сформированные на основе матриц ДВП путем их усреднения по всем масштабам на каждом временном сдвиге.

Отметим, что построение векторов признаков из матриц ДВП возможно, и по переменной n , и по переменной m . Выбор в пользу последней переменной m обусловлен результатами, полученными в [4].

Для оценки контрастности векторов признаков, сформированных на основе ДВП, использующего вейвлет Гаусса 2-го порядка, воспользуемся формулой (1).

Ниже представлены результаты взаимной контрастности векторов признаков между эталонным и текущим изображением, а также эталонным и изображением шляпки.

$${}^{\text{III}}d = \frac{1}{256} \sum_{m=0}^{255} |{}^{\circ}V_m - {}^{\text{III}}V_m| = 0,15,$$

$${}^{\text{I}}d = \frac{1}{256} \sum_{m=0}^{255} |{}^{\circ}V_m - {}^{\text{I}}V_m| = 0,019.$$

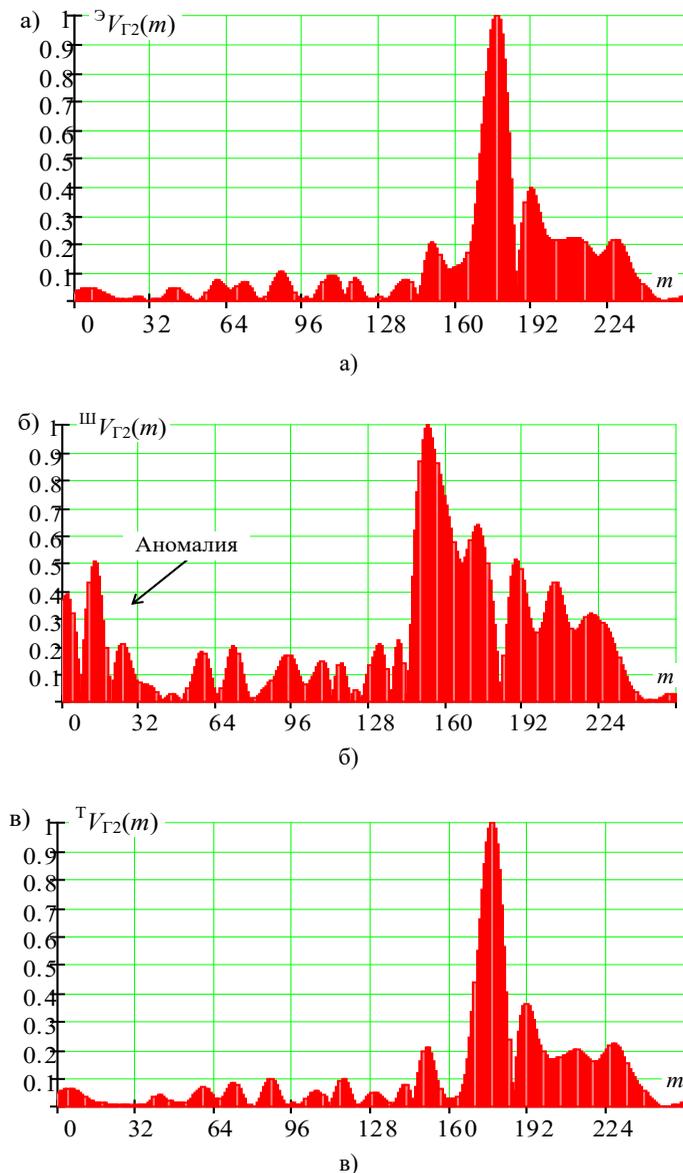


Рис. 13. а) вектор признаков эталонного изображения на основе вейвлета Гаусса 2-го порядка; б) вектор признаков изображения со шляпкой на основе вейвлета Гаусса 2-го порядка; в) вектор признаков текущего изображения на основе вейвлета Гаусса 2-го порядка

Полученные результаты показывают, что для рассматриваемого примера различия в контрастности между парами разностей составляют почти 7,9 раз.

Следует отметить, что если в качестве эталона рассматривать текущее изображение, то различия увеличатся в 8,3 раза.

Для лучшей наглядности результатов исследования на рисунке 14 представлены функции различий между векторами признаков эталонного изображения и изображения со шлюпкой, полученные на основе гистограмм и ДВП с вейвлетом Гаусса 2-го порядка, рассчитанные по формуле

$${}^{\text{эТ}}d_{\Gamma\Gamma\Gamma_2}(m) = |{}^{\text{эТ}}V_m - {}^{\text{Т}}V_m|, \quad (11)$$

где ${}^{\text{эТ}}d_{\Gamma\Gamma}(m)$ – функция разности между векторами признаков нижний индекс эталонного изображения и изображения со шлюпкой, полученные на основе гистограмм;

${}^{\text{эТ}}d_{\Gamma_2}(m)$ – функция разности между векторами признаков нижний индекс эталонного изображения и изображения со шлюпкой, полученные на основе ДВП, использующего в качестве материнского вейвлета функцию Гаусса 2-го порядка.

Очевидно, что дисперсия вектора ${}^{\text{эТ}}d_{\Gamma_2}(m)$ существенно превосходит аналогичный показатель вектора ${}^{\text{эТ}}d_{\Gamma\Gamma}(m)$, что позволяет судить о повышении контрастности признакового пространства, сформированного на основе матриц ДВП.

Учитывая, что обнаружение, в данном случае спасательной шлюпки, будет происходить на фоне динамически изменяющейся морской поверхности, то такой процесс будет носить вероятностный характер.

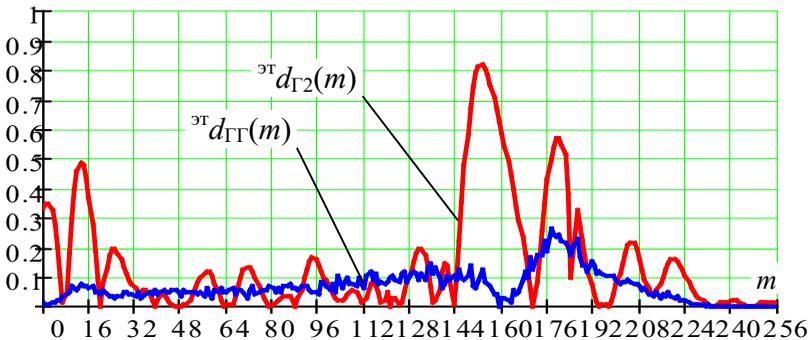


Рис. 14. Функции разности векторов признаков

Поскольку рассмотренный подход к обнаружению аномалий основан на статистической обработке параметров изображений, то открывается возможность оценки его эффективности, с позиций вероятностных показателей.

Подходы к вероятностной оценке распознавания объектов по результатам обработки изображений известны. Однако все они, как правило, ориентированы на определенные условия.

Так в [39], вероятность распознавания рассмотрена с позиций возможностей аппаратуры и условия наблюдения. Полученная в работе аналитическая зависимость носит эмпирический характер и содержит большое количество различных уточняющих коэффициентов и параметров. Однако в основу вероятностного выражения составляет величина отношения площади объекта к общей площади изображения.

В [40] получено аналитическое выражение вероятности правильного обнаружения с позиций обнаружения сигналов в шумах по критерию Байеса и Неймана–Пирсона, по результатам обработки отношения плотностей распределения вероятностей. В основе используемой аналитики авторы рассматривают отношение математического ожидания к дисперсии функции правдоподобия при условии наличия и отсутствия распознаваемого объекта на обрабатываемом изображении.

Очевидно, что такой подход правомерен, поскольку любая внесенная аномалия приводит к изменению статистических параметров изображения. При этом авторы справедливо отмечают, что такой подход применим в предположении «... гауссовости яркостей обрабатываемых изображений как в отсутствие сигнала, так и при его наличии ...» [40]. Поэтому предлагают обнаруживать аномалии по результатам предварительной фильтрации общего фона. Но такое решение изначально предполагает высокую статичность фона, что сложно реализуемо в морских акваториях.

Вместе с тем анализ указанных подходов позволяет сделать вывод о том, что основными параметрами, определяющими качество распознавания, являются относительные размеры объекта распознавания к общему размеру кадра изображения и вариативность структуры окружающего идентифицируемый объект фона. Следовательно, эти параметры и должны определять величину искомой вероятности распознавания.

Поскольку в рассматриваемой ситуации в качестве обрабатываемых данных выступают векторы признаков, представленные на рисунке 12, то в основу подхода к распознаванию аномалий, приводящих к изменению их структуры, целесообразно

определить способы, используемые при обнаружении сигнала с неизвестной амплитудой.

Согласно [41], в таких способах величина условной вероятности правильного обнаружения $P_{\text{по}}$ определяется текущим значением отношения сигнал/шума h^2 на входе решающего устройства

$$P_{\text{по}} = \begin{cases} 0,5 [1 + \Phi(h - G_0)], & h \geq G_0; \\ 0,5 [1 - \Phi(G_0 - h)], & h < G_0, \end{cases} \quad (12)$$

где G_0 – нормированный порог обнаружения; $\Phi(*)$ – функция Крампа.

$$\Phi(G_0) = \sqrt{\frac{2}{\pi}} \int_0^{G_0} \exp\left(-\frac{t^2}{2}\right) dt.$$

В терминах аналогий можно полагать, что в качестве шума, в рассматриваемом случае, будут выступать различия между исходным (эталонным) изображением и обрабатываемым.

В общем случае, задача вероятности обнаружения будет состоять в выявлении различий, вызванных наличием искомым аномалий на обрабатываемом изображении. Но поскольку в качестве фона изображений выступает водная поверхность, то даже в отсутствии аномалий, вызванных искомого объекта распознавания, эталонное и текущее изображения будут отличаться друг от друга.

Очевидно, что чем сильнее будут эти различия, тем сложнее будет выявить изменения, обусловленные наличием аномалий. В свою очередь изменения вектора признаков, вызванные наличием аномалий, будут зависеть от их размеров на обрабатываемом кадре изображения. Это связано с тем, что наличие аномалий приводит к амплитудным изменениям соответствующим им элементам векторов признаков. Поэтому чем крупнее объект (аномалия) в пределах обрабатываемого кадра, тем больше количество пикселей будут описывать его изображение. И, следовательно, соответствующие ему элементы вектора признаков получают большие амплитудные значения. Тем самым повысится контрастность вектора признаков.

Поэтому, с рассмотренных позиций, в формуле (12) величину h^2 предлагается рассматривать в виде

$$h^2 = B / \sigma, \quad (13)$$

где $B \in [0; 1]$ – относительные размеры объекта распознавания на кадре изображения, σ – величина среднего квадратического разброса параметров вектора признаков.

Ограничением предложенного подхода является условие, что различия между двумя любыми изображениями из рассматриваемого признакового пространства не должны превышать величины σ .

Значение порога G_0 в формуле (12) будет определять величину различий между векторами признаков эталонного и обрабатываемого изображений, вызванных наличием аномалий, превышение которых позволяет их идентифицировать (отнести к искомому объекту).

Тогда с учетом введенных допущений можно получить графики зависимости вероятности обнаружения в кадре изображения аномалии (искомого объекта) в заданном пространстве распознавания (рисунок 15).

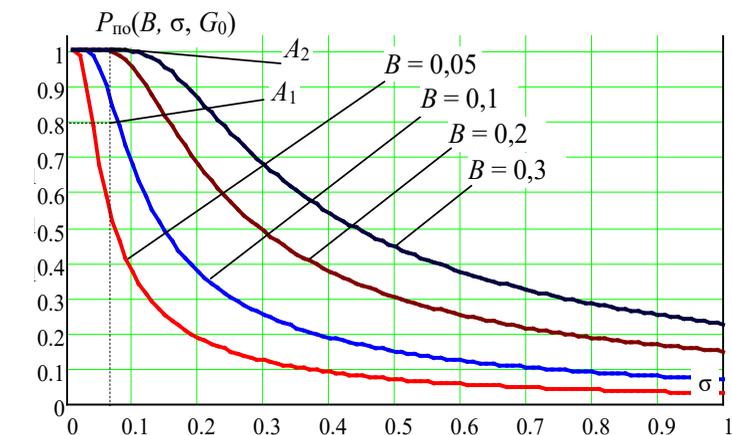


Рис. 15. Вероятность правильного обнаружения (распознавания) аномалий на кадрах изображений

Представленные на рисунке 15 зависимости получены при значении величины порога $G_0 = 0,01$.

Согласно полученным результатам, при величине $\sigma = 0,1$ обнаружение аномалий с вероятностью не менее 0,95 становится возможным, если их размеры будут занимать не менее 20% от общей площади обрабатываемого кадра изображения.

При этом снижение размера аномалии до 10% от общей площади кадра, приведет к снижению вероятности ее обнаружения до

уровня 0,7. А при размерах аномалий порядка 5%, вероятность их обнаружения снизится до значения 0,4.

В ходе моделирования использовались 200 различных изображений, для которых векторы признаков строились на основе гистограмм распределения яркости.

Так, на рисунке 6 представлено текущее изображение (из числа используемых для моделирования), которое имеет наибольшие различия с эталонным изображением (рисунок 3). В рассматриваемом случае величина средних квадратических различий достигает $\sigma = 0,07$.

При этом размер шляпки занимает порядка 7% от общей площади кадра изображения, поэтому вероятность правильного обнаружения достигает величины $P_{по} = 0,8$ (точка A_1 на рисунке 15).

Заметим, что в представленном варианте выражение для расчета вероятности правильного обнаружения не учитывает дополнительную контрастность, которая обеспечивается при переходе к формированию векторов признаков на основе реализации процедур ДВП.

Для учета контрастности, обеспечиваемой процедурами ДВП, предлагается использовать коэффициент повышения контрастности $K_{пк}$, который можно рассчитать, применительно к проведенному исследованию, как

$$K_{пк} = \frac{{}^{эш}d_{Г2} / {}^{эт}d_{Г2}}{{}^{эш}d_{ГГ} / {}^{эт}d_{ГГ}}, \quad (14)$$

где ${}^{эш}d_{ГГ} / {}^{эт}d_{ГГ}$ – отношение векторов разности, сформированных на основе гистограмм распределения яркости; ${}^{эш}d_{Г2} / {}^{эт}d_{Г2}$ – отношение векторов разности, сформированных на основе ДВП в базисе вейвлетов Гаусса 2-го порядка.

Для рассмотренных условий:

$${}^{эш}d_{ГГ} / {}^{эт}d_{ГГ} = 2,3;$$

$${}^{эш}d_{Г2} / {}^{эт}d_{Г2} = 7,9.$$

Следовательно, коэффициент повышения контрастности будет равен $K_{пк} = 3,4$.

Поскольку повышение контрастности эквивалентно увеличению размера распознаваемого объекта, то результирующее выражение для оценки вероятности правильного обнаружения аномалий с учетом коэффициента повышения контрастности можно записать как

$$P_{\text{по}} = \begin{cases} 0,5 \left[1 + \Phi \left(\frac{BK_{\text{пк}}}{\sigma} - G_0 \right) \right], & \frac{BK_{\text{пк}}}{\sigma} \geq G_0; \\ 0,5 \left[1 - \Phi \left(G_0 - \frac{BK_{\text{пк}}}{\sigma} \right) \right], & \frac{BK_{\text{пк}}}{\sigma} < G_0. \end{cases} \quad (15)$$

С учетом выражения (15), т.е. при формировании векторов признаков на основе ДВП, вероятность правильного обнаружения аномалий достигает величины $P_{\text{по}} = 0,99$ (точка A_2 на рисунке 14).

Отметим, что по аналогии [42], используемой для обоснования вероятности правильного обнаружения, можно получить и величину вероятности ложной тревоги

$$P_{\text{лт}} = 0,5 \left[1 - \Phi \left(\frac{G_0}{\sqrt{2}B/\sigma} \right) \right]. \quad (16)$$

Полученные результаты указывают на достижение поставленной цели.

6. Заключение. Полученные результаты указывают на правомерность выбранного подхода к повышению контрастности векторов признаков, позволивших повысить достоверность выявления аномалий на изображениях при формировании их векторов признаков в базах вейвлетов. Дальнейшие исследования авторы связывают с более детальной проработкой метода вероятностной оценки результатов распознавания.

Литература

1. Киджи Д.С., Ольховик Е.О. Методика районирования акватории Северного морского пути при проведении аварийноспасательных работ и ликвидации разливов нефти // Вестник государственного университета морского и речного флота им. адмирала С.О. Макарова. 2023. Т. 15. № 6. С. 1030–1040. DOI: 10.21821/2309-5180-2023-15-6-1030-1040.
2. Абросимов В.К., Матвеева Ю.Н. Формирование синтетических данных для машинного обучения распознаванию подводных объектов // Робототехника и техническая кибернетика. 2023. Т. 11. № 4. С. 256–266. DOI: 10.31776/RTSJ.11402.
3. Кузьмин О.В., Лавлинская А.А., Тараканов Б.А., Федоренко М.А., Былков Е.Г., Харитонов И.А. Проектирование БПЛА для мониторинга лесных массивов и водных пространств при помощи Autodesk Fusion 360 // Информационные технологии, их приложения и информационное образование: Материалы II Международной научной конференции (г. Улан-Удэ – Гусиноозерск, 20–22 августа 2021 г.) Улан-Удэ: Бурятский государственный университет имени Доржи Банзарова, 2021. С. 168–177.

4. Дворников С.В., Дворников С.С., Васильева Д.В. Автоматизация процедур обнаружения нефтяных разливов на водной поверхности // *Информация и космос*. 2024. № 1. С. 126–132.
5. Бударова В.А., Воронина Е.А., Дубровский А.В., Кустышева И.Н., Малыгина О.И., Мартынова Н.Г., Торсунова О.Ф. Нормативно-правовые особенности установления водоохраных зон и прибрежных защитных полос (на примере территории Новосибирской области) // *Вестник СГУиТ (Сибирского государственного университета геосистем и технологий)*. 2020. Т. 25. № 1. С. 222–238. DOI: 10.33764/2411-1759-2020-25-1-222-238.
6. Martyshev M.I., Nikitenko D.A. Preprocessing of system monitoring data for workload analysis of HPC systems // *Numerical Methods and Programming*. 2021. vol. 22. no. 3. pp. 230–238. DOI 10.26089/NumMet.v22r314.
7. Родионов В.В., Ищук И.Н., Громов Ю.Ю. Применение технологий искусственного интеллекта в задачах обработки данных дистанционного мониторинга поверхности земли // *Автоматизация в промышленности*. 2024. № 1. С. 26–28. DOI: 10.25728/avtprom. 2024.01.06.
8. Горбунова Э.М., Беседина А.Н., Кабыченко Н.В., Батухтин И.В., Петухова С.М. Прецизионный гидрогеологический мониторинг в техногенно-нарушенных условиях: организация, проведение и обработка экспериментальных данных // *Сейсмические приборы*. 2021. Т. 57. № 2. С. 62–80. DOI: 10.21455/si.2021.2-4.
9. Чан Х.Н., Подстригаев А.С., Нгуен Ч.Н., Иконенко Д.А. Оценка достоверности распознавания сигналов для алгоритма распознавания с детектированием на двух промежуточных частотах // *Успехи современной радиоэлектроники*. 2023. Т. 77. № 10. С. 70–79. DOI: 10.18127/j20700784-202310-07.
10. Васильева Д.В., Якушенко С.А., Дворников С.В., Погорелов А.А., Дворников С.В. Обнаружение морских дронов в оптическом диапазоне // *Морской вестник*. 2023. № 4(88). С. 90–92.
11. Ван Л., Петросян О.Г. Распознавание лиц на основе классификации вейвлет признаков путём выветл нейронных сетей // *Информатизация образования и науки*. 2018. № 4(40). С. 129–139.
12. Гочаков А.В. Задача распараллеливания вейвлет-преобразования для фильтрации зашумленных видеоизображений // *Труды Новосибирского государственного архитектурно-строительного университета (Сибстрин)*. 2011. Т. 14. № 2(51). С. 85–89.
13. Dvornikov S., Ustinov A., Okov I. Statistical Arithmetic Coding Algorithm Adaptive to Correlation Properties of Wavelet Transform Coefficients // *Proceedings of Telecommunication Universities*. 2022. vol. 8. no. 3. pp. 6–12. DOI: 10.31854/1813-324X-2022-8-3-6-12.
14. Дубина В.А., Катин И.О., Боброва М.А., Плотников В.В. Кораблекрушение на границе морского заповедника. Результаты спутникового мониторинга // *Современные проблемы дистанционного зондирования Земли из космоса*. 2020. Т. 17. № 1. С. 267–270. DOI: 10.21046/2070-7401-2020-17-1-267-270.
15. Родионов А.Г., Ефимов В.В., Тварин Ю.Г. Искусственный интеллект в судовождении - игра в имитацию? (По материалам зарубежных и открытых источников) // *Морской вестник*. 2022. № 4(84). С. 95–102.
16. Сенцов А.А., Ненашев В.А., Иванов С.А., Турнецкая Е.Л. Совмещение сформированных радиолокационных изображений с цифровой картой местности в бортовых системах оперативного мониторинга земной поверхности // *Труды МАИ*. 2021. № 117. DOI: 10.34759/trd-2021-117-08.
17. Гибадуллин Р.Ф., Смирнов И.Н., Хевронин Н.В., Никитин А.В., Перухин М.Ю. Разработка аппаратно-программного модуля обнаружения объектов для

- встраиваемых систем // Вестник Технологического университета. 2018. Т. 21. № 6. С. 118–122.
18. Janati M., Kolahdoozan M., Imanian H. Artificial Neural Network Modeling for the Management of Oil Slick Transport in the Marine Environments. *Pollution*. 2020. vol. 6. no. 2. pp. 399–415.
 19. 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.
 20. Stockman G., Shapiro L.G. *Computer Vision*. 1st ed. Prentice Hall PTR: Upper Saddle River, NJ, USA, 2001. 617 p.
 21. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016. pp. 770–778.
 22. Howard A.G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Andreetto M., Adam H. MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*. 2017.
 23. Фукунага К. Введение в статистическую теорию распознавания образов / Пер. с англ. Москва: Наука, 1979. 368 с.
 24. Буланов В.А., Волосатова Т.М. Программный комплекс предварительной обработки изображений для обнаружения и распознавания изображений // Наука и образование: научное издание МГТУ им. Н.Э. Баумана. 2014. № 4. С. 321–338. DOI: 10.7463/0414.0707888.
 25. 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.
 26. 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.
 27. Zimek A., Schubert E. Outlier Detection // *Encyclopedia of Database Systems*. 2017. DOI: 10.1007/978-1-4899-7993-3_80719-1.
 28. Васильева Д.В., Дворников С.С., Толстуха Ю.Е., Обрезков П.С., Дворников С.В. Формирование векторов признаков для систем видеонаблюдения // *Вопросы радиоэлектроники*. Серия: Техника телевидения. 2023. № 4. С. 62–68.
 29. Казарян М.Л., Рихтер А.А., Шахрамьян М.А. Символические матрицы и их применение при решении систем многочленных уравнений и обработке изображений // *Информация и космос*. 2021. № 3(1). С. 86–95.
 30. Дворников С.В., Балыков А.А. Предложения по управлению скоростью передачи и помехоустойчивостью сигналов с перестановочной частотной модуляцией // *T-Comm: Телекоммуникации и транспорт*. 2020. Т. 14. № 6. С. 20–26. DOI: 10.36724/2072-8735-2020-14-6-20-26.
 31. Макаренко А.А. Вариант применения цифровой обработки изображений для распознавания текстов на оптикоэлектронном изображении // *Радиопрмышленность*. 2021. Т. 31. № 2. С. 15–21. DOI: 10.21778/2413-9599-2021-31-2-15-21.
 32. The First Half-Tones. *Library and Archives of Canada*. 2009.
 33. Умбиталиев А.А., Дворников С.В., Оков И.Н., Устинов А.А. Способ сжатия графических файлов методами вейвлет-преобразований // *Вопросы радиоэлектроники*. Серия: Техника телевидения. 2015. № 3. С. 100–106.
 34. Горбачев В.Н., Казаков А.Я., Савельева М.Ю. Вейвлет-преобразование полутонного изображения в конечном поле // *Оптический журнал*. 2021. Т. 88. № 2. С. 40–49. DOI: 10.17586/1023-5086-2021-88-02-40-49.

35. Дейцева А.Г. Построение базисных вейвлетов и фреймов с помощью финитных функций. Соболевский вейвлет // Вестник БГУ. Серия 1, Физика. Математика. Информатика. 2006. № 2. С. 75–79.
36. Велигоша А.В., Мальшко Н.Н., Струков Р.И. Применение искусственных нейронных сетей для снижения избыточности дискретного вейвлет-преобразования // Теория и техника радиосвязи. 2020. № 2. С. 5–12.
37. 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.
38. Лаврентьева А.С., Новиков В.А., Семенова М.Ю., Фидельман В.Р. Применение дискретного вейвлет-преобразования для определения символьной скорости коротких выборок фазоманипулированного сигнала // Известия высших учебных заведений. Поволжский регион. Технические науки. 2016. № 1(37). С. 92–102.
39. Сельвесюк Н.И., Веселов Ю.Г., Гайденов А.В., Островский А.С. Оценка характеристик обнаружения и распознавания объектов на изображении от специальных оптико-электронных систем наблюдения летного поля // Труды МАИ. 2018. № 103.
40. Андриянов Н.А., Дементьев В.Е., Ташлинский А.Г. Обнаружение объектов на изображении: от критериев Байеса и Неймана–Пирсона к детекторам на базе нейронных сетей EfficientDet // Компьютерная оптика. 2022. Т. 46. № 1. С. 139–159. DOI: 10.18287/2412-6179-СО-922.
41. Дворников С.В. Метод обнаружения сигналов диапазона ВЧ на основе двухэтапного алгоритма принятия решения // Научное приборостроение. 2005. Т. 15. № 3. С. 114–119.

Дворников Сергей Викторович — д-р техн. наук, профессор кафедры, кафедра радиотехнических и оптоэлектронных комплексов, Федеральное государственное автономное образовательное учреждение высшего образования «Санкт-Петербургский государственный университет аэрокосмического приборостроения» (ГУАП); кафедра радиосвязи, Военная академия связи им. Маршала Советского Союза С.М. Буденного. Область научных интересов: построение помехозащищенных систем радиосвязи, формирование и обработка сигналов сложных структур. Число научных публикаций — 448. practicdsv@yandex.ru; Тихорецкий проспект, 3, 194064, Санкт-Петербург, Россия; р.т.: +7(812)247-9400.

Васильева Дина Владимировна — аспирант, старший преподаватель кафедры, кафедры радиотехнических систем института радиотехники и инфокоммуникационных технологий, Федеральное государственное автономное образовательное учреждение высшего образования «Санкт-Петербургский государственный университет аэрокосмического приборостроения» (ГУАП). Область научных интересов: цифровая обработка сигналов. Число научных публикаций — 15. dolli.dina@mail.ru; улица Большая Морская, 67А, 190000, Санкт-Петербург, Россия; р.т.: +7(931)385-9181.

S. DVORNIKOV, D. VASILIEVA
**INCREASE OF RELIABILITY OF ANOMALIES DETECTION
ON IMAGES AT FORMATION OF THEIR FEATURE VECTORS
IN WAVELET BASES**

Dvornikov S., Vasilieva D. Increase of Reliability of Anomalies Detection on Images at Formation of Their Feature Vectors in Wavelet Bases.

Abstract. The method of detection of life rafts and lifeboats in the water area of seas and oceans after shipwrecks based on the recognition of anomalies in the processed images, which increases the probability of recognition of monitoring objects, is proposed. The approach to solving such a problem is substantiated. The formulation of the problem of object recognition from the perspective of binary classification in the detection of anomalies is presented. The analytical expression for the decision-making algorithm is obtained. The possibility of formalization of image matrices in the form of histograms of color (brightness) intensity distributions is considered. The contrast of the feature space on their basis is estimated. It is suggested that the contrast of feature spaces be increased due to the secondary processing of histograms of distributions in the basis of multiple-scale wavelet decomposition. The possibility of realization of wavelet transformations on the basis of Haar functions and Gauss wavelets of the 1st and 2nd orders is considered. The mechanism of formation of secondary feature vectors from three-dimensional wavelet transforms by averaging their coefficients along the time shift axis is substantiated. It is shown that at the same dimensionality of histograms of brightness distribution with newly formed feature vectors, the latter provide higher contrast of feature spaces. It is recommended to use a Gaussian wavelet of the 2nd order for the formalization of images in jpeg format, which provides, other things being equal, a greater magnitude of differences for images containing anomalies. An approach to probabilistic evaluation of the algorithm for automatic image recognition is developed. The analytical expression is obtained and its constituent elements are justified. Graphical dependences of the probability of correct detection (recognition) of anomalies, depending on the size in relation to the total area of the frame and the dispersion of the underlying background are given. The results of the experiment on image recognition with a lifeboat in the ocean water area are presented. The directions of further research are defined.

Keywords: image recognition, feature vectors, wavelet transform, contrast of feature spaces.

References

1. Kiji D.S., Olkhovik E.O. [Methodology of zoning the water area of the Northern Sea Route during emergency rescue operations and oil spill response]. *Vestnik gosudarstvennogo universiteta morskogo i rechnogo flota im. admirala S.O. Makarova – Bulletin of the State University of Sea and River Fleet named after Admiral S.O. Makarov*. 2023. vol. 15. no. 6. pp. 1030–1040. DOI: 10.21821/2309-5180-2023-15-6-1030-1040. (In Russ.).
2. Abrosimov V.K., Matveeva Yu.N. [Formation of synthetic data for machine learning to recognize underwater objects]. *Robototekhnika i tekhnicheskaya kibernetika – Robotics and Technical Cybernetics*. 2023. vol. 11. no. 4. pp. 256–266. DOI: 10.31776/RTCJ.11402. (In Russ.).
3. Kuzmin O.V., Lavlinskaya A.A., Tarakanov B.A., Fedorenko M.A., Bylkov E.G., Haritonov I.A. [Designing UAVs for monitoring forests and water spaces using Autodesk Fusion 360] *Informacionnye tekhnologii, ih prilozheniya i informacionnoe*

- obrazovanie: Materialy II Mezhdunarodnoj nauchnoj konferencii [Information technologies, their applications and information education: Proceedings of the II International Scientific Conference]. Ulan-Ude: Dorzhi Banzarov Buryat State University. 2021. pp. 168–177. (In Russ.).
4. Dvornikov S.V., Dvornikov S.S., Vasilieva D.V. [Automation of the oil spill detection procedures on the water surface]. *Informaciya i kosmos – Information and Space*. 2024. no. 1. pp. 126–132. (In Russ.).
 5. Budarova V.A., Voronina E.A., Dubrovsky A.V., Kustysheva I.N., Malygina O.I., Martynova N.G., Torsunov O.F. [Normative and legal features of establishing water protection zones and coastal protective strips (by the example of the territory of the Novosibirsk region)]. *Vestnik SGUGiT (Sibirskogo gosudarstvennogo universiteta geosistem i tekhnologij) – Bulletin of SGUGiT (Siberian State University of Geosystems and Technologies)*. 2020. vol. 25. no. 1. pp. 222–238. DOI: 10.33764/2411-1759-2020-25-1-222-238. (In Russ.).
 6. Martyshev M.I., Nikitenko D.A. Preprocessing of system monitoring data for workload analysis of HPC systems. *Numerical Methods and Programming*. 2021. vol. 22. no. 3. pp. 230–238. DOI 10.26089/NumMet.v22r314.
 7. Rodionov V.V., Ishchuk I.N., Gromov Yu.Yu. [Application of artificial intelligence technologies in the tasks of processing the data of remote monitoring of the earth surface]. *Avtomatizaciya v promyshlennosti – utomation in industry*. 2024. no. 1. pp. 26–28. DOI: 10.25728/avtprom. 2024.01.06. (In Russ.).
 8. Gorbunova E.M., Besedina A.N., Kabychenko N.B., Batuhin I.V., Petuhova S.M. [Precision hydrogeological monitoring in technogenically disturbed conditions: organization, conduct and processing of experimental data]. *Seismicheskie pribory – Seismic Devices*. 2021. vol. 57. no. 2. pp. 62–80. DOI: 10.21455/si.2021.2-4. (In Russ.).
 9. Chan H.N., Podstrigaev A.S., Nguyen C.N., Ikonenko D.A. [Estimation of signal recognition reliability for the recognition algorithm with detection at two intermediate frequencies]. *Uspekhi sovremennoi radioelektronics – Advances in modern radio electronics*. 2023. vol. 77. no. 10. pp. 70–79. DOI: 10.18127/j20700784-202310-07. (In Russ.).
 10. Vasilieva D.V., Yakushenko S.A., Dvornikov S.B., Pogorelov A.A., Dvornikov S.V. [Detection of marine drones in the optical range]. *Morskoy vestnik – Marine Bulletin*. 2023. no. 4(88). pp. 90–92. (In Russ.).
 11. Wang L., Petrosyan O.G. [Face recognition based on wavelet feature classification by wavelet neural networks]. *Informatizaciya obrazovaniya i nauki – Informatization of education and science*. 2018. no. 4(40). pp. 129–139. (In Russ.).
 12. Gochakov A.V. [Parallelization problem wavelet transform for filtering of noisy video images] *Trudy Novosibirskogo gosudarstvennogo arhitekturno-stroitel'nogo universiteta (Sibstrin) [Proceedings of Novosibirsk State University of Architecture and Civil Engineering (Sibstrin)]*. 2011. vol. 14. no. 2(51). pp. 85–89. (In Russ.).
 13. Dvornikov S., Ustinov A., Okov I. Statistical Arithmetic Coding Algorithm Adaptive to Correlation Properties of Wavelet Transform Coefficients. *Proceedings of Telecommunication Universities*. 2022. vol. 8. no. 3. pp. 6–12. DOI: 10.31854/1813-324X-2022-8-3-6-12.
 14. Дубина В.А., Катин И.О., Боброва М.А., Плотников В.В. Кораблекрушение на границе морского заповедника. Результаты спутникового мониторинга. *Современные проблемы дистанционного зондирования Земли из космоса*. 2020. Т. 17. № 1. С. 267–270. DOI: 10.21046/2070-7401-2020-17-1-267-270.
 15. Rodionov A.G., Efimov V.V., Tvarin Yu.G. [Artificial intelligence in ship navigation – a game of imitation? (On the materials of foreign and open sources)]. *Morskoy vestnik – Marine Bulletin*. 2022. no. 4(84). pp. 95–102. (In Russ.).

16. Sentsov A.A., Nenashev V.A., Ivanov S.A., Tournetskaya E.L. [Alignment of the generated radar images with the digital terrain map in the onboard systems of the operational monitoring of the Earth surface] Trudy MAI [Proceedings of MAI]. 2021. no. 117. DOI: 10.34759/trd-2021-117-08. (In Russ.).
17. Gibadullin R.F., Smirnov I.N., Khevronin N.B., Nikitin A.V., Peruhin M.Yu. [Development of hardware and software object detection module for embedded systems]. Vestnik Tekhnologicheskogo universiteta – Vestnik of Technological University. 2018. vol. 21. no. 6. pp. 118–122. (In Russ.).
18. Janati M., Kolahdoozan M., Imanian H. Artificial Neural Network Modeling for the Management of Oil Slick Transport in the Marine Environments. Pollution. 2020. vol. 6. no. 2. pp. 399–415.
19. 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.
20. Stockman G., Shapiro L.G. Computer Vision. 1st ed. Prentice Hall PTR: Upper Saddle River, NJ, USA, 2001. 617 p.
21. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2016. pp. 770–778.
22. Howard A.G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Andreetto M., Adam H. MobileNets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861. 2017.
23. Fukunaga K. Vvedenie v statisticheskuyu teoriyu raspoznavaniya obrazov [Introduction to the statistical theory of pattern recognition]. Moscow: Nauka, 1979. 367 p. (In Russ.).
24. Bulanov V.A., Volosatova T.M. [Program complex of preliminary image processing for image detection and recognition]. Nauka i obrazovanie: nauchnoe izdanie MGITU im. N.E. Baumana – Science and Education: scientific edition of Bauman Moscow State Technical University. 2014. no. 4. pp. 321–338. DOI: 10.7463/0414.0707888. (In Russ.).
25. 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.
26. 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.
27. Zimek A., Schubert E. Outlier Detection. Encyclopedia of Database Systems. 2017. DOI: 10.1007/978-1-4899-7993-3_80719-1.
28. Vasilieva D.V., Dvornikov S.S., Tolstukha Y.E., Obrezkov P.S., Dvornikov S.V. [Formation of feature vectors for video surveillance systems]. Voprosy radioelektroniki. Seriya: Tekhnika televideniya – Questions of Radio Electronics. Series: Television Technology. 2023. no. 4. pp. 62–68. (In Russ.).
29. Kazarian M.L., Richter A.A., Shahramanian M.A. [Symbolic matrices and their application in solving systems of polynomial equations and image processing]. Informaciya i kosmos – Information and Space. 2021. no. 3. pp. 86–95. (In Russ.).
30. Dvornikov S.V., Balykov A.A. [Proposals for controlling the transmission rate and noise immunity of signals with permutation frequency modulation]. T-Comm: Telekomunikacii i transport – T-Comm: Telecommunications and Transportation. 2020. vol. 14. no. 6. pp. 20–26. DOI: 10.36724/2072-8735-2020-14-6-20-26. (In Russ.).
31. Makarenko A.A. [Variant of application of digital image processing for texture recognition on the optoelectronic image]. Radiopromyshlennost' – Radio Industry. 2021. vol. 31. no. 2. pp. 15–21. DOI: 10.21778/2413-9599-2021-31-2-15-21. (In Russ.).

32. The First Half-Tones. Library and Archives of Canada. 2009.
33. Umbitaliev A.A., Dvornikov S.V., Okov I.N., Ustinov A.A. [Method of compression of graphic files by methods of wavelet transformations]. *Voprosy radioelektroniki. Seriya: Tekhnika televideniya – Questions of Radio Electronics. Series: Television Technology*. 2015. no. 3. pp. 100–106. (In Russ.).
34. Gorbachev V.N., Kazakov A.Y., Savelyeva M.Yu. [Wavelet transformation of a halftone image in a finite field]. *Opticheskij zhurnal – Optical Journal*. 2021. vol. 88. no. 2. pp. 40–49. DOI: 10.17586/1023-5086-2021-88-02-40-49. (In Russ.).
35. Дейтсева А.Г. [Deitseva A.G. Construction of basis wavelets and frames with the help of finite functions. Sobolev wavelet]. *Vestnik BGU. Seriya 1, Fizika. Matematika. Informatika – BSU Bulletin. Series 1, Physics. Mathematics. Computer Science*. 2006. no. 2. pp. 75–79. (In Russ.).
36. Veligosha A.V., Malyshko N.N., Strukov R.I. [Application of artificial neural networks to reduce the redundancy of discrete wavelet transform] *Teoriya i tekhnika radiosvyazi – Theory and technique of radio communication*. 2020. no. 2. pp. 5–12. (In Russ.).
37. Say S.V., Zinkevich A.V., Fomina E.C. [Comparison of discrete cosine and wavelet transforms in RAW-image compression systems]. *Komp'yuternaya optika – Computer Optics*. 2022. vol. 46. no. 6. pp. 929–938. DOI: 10.18287/2412-6179-CO-1094. (In Russ.).
38. Lavrentieva A.S., Novikov V.A., Semenova M.Yu., Fidelman V.R. [Application of discrete wavelet transformation for the Determination of the symbolic rate of short samples of a phase-manipulated signal]. *Izvestiya vysshih uchebnyh zavedenij. Povolzhskij region. Tekhnicheskie nauki – News of higher educational institutions. Volga region. Technical sciences*. 2016. no. 1(37). pp. 92–102. (In Russ.).
39. Selvesyuk N.I., Veselov Y.G., Gaidenkov A.V., Ostrovsky A.S. [Evaluation of the characteristics of detection and recognition of objects in the image from special optical-electronic systems of airfield observation] *Trudy MAI [Proceedings of MAI]*. 2018. no. 103. (In Russ.).
40. Andriyanov N.A., Dementiev V.E., Tashlinsky A.G. [Object detection on the image: from the Bayes and Neyman-Pearson criteria to the detectors based on the EfficientDet neural networks]. // *Komp'yuternaya optika – Computer Optics*. vol. 46. no. 1. pp. 139–159. DOI: 10.18287/2412-6179-CO-922 (In Russ.).
41. Dvornikov S.V. [Method of detection of RF signals on the basis of two-stage algorithm of decision making]. *Nauchnoe instrumentostroenie – Scientific instrumentation*. 2005. vol. 15. no. 3. pp. 114–119. (In Russ.).

Dvornikov Sergey — Ph.D., Dr.Sci., Professor of the department, Department of radio engineering and optoelectronic complexes, Federal State Autonomous Educational Institution of Higher Education «St. Petersburg State University of Aerospace Instrumentation» (SUAI); Department of radio communications, Military Academy of Communications named after Marshal of the Soviet Union S.M. Budyonny. Research interests: construction of noise-protected radio communication systems, formation and processing of signals of complex structures. The number of publications — 448. practicdsv@yandex.ru; 3, Tikhoretsky Av., 194064, St. Petersburg, Russia; office phone: +7(812)247-9400.

Vasilieva Dina — Postgraduate student, senior lecturer of the department, Department of radio engineering systems, institute of radio engineering and info-communication technologies, Federal State Autonomous Educational Institution of Higher Education «St. Petersburg State University of Aerospace Instrumentation» (SUAI). Research interests: digital signal processing. The number of publications — 15. dolli.dina@mail.ru; 67A, Bolshaya Morskaya St., 190000, St. Petersburg, Russia; office phone: +7(931)385-9181.