

УДК 616.37, 004.932, 004.89

DOI: [10.26102/2310-6018/2023.40.1.021](https://doi.org/10.26102/2310-6018/2023.40.1.021)

Автоматизированная система классификации снимков УЗИ поджелудочной железы на основе метода посегментного спектрального анализа

С.А. Филист¹✉, Д.С. Кондрашов¹, А.Ю. Сухомлинов¹, Л.В. Шульга¹, Ч.Х. Аль-Дарраджи^{1,2}, В.А. Белозёров³

¹Юго-Западный государственный университет, Курск, Российская Федерация

²Университет Дияла, Баакубу, Республика Ирак

³Курская областная многопрофильная клиническая больница, Курск, Российская Федерация
sfilist@gmail.com✉

Резюме. Классификация снимков УЗИ является превалирующим инструментом в постановке диагноза многих заболеваний поджелудочной железы. Для интерпретации ультразвукового изображения врачом требуются годы подготовки и опыта. Поэтому разработка моделей, методов и алгоритмов повышения достоверности и качества интерпретации снимков УЗИ за счет применения специализированных программных средств, позволяющих снизить риск диагностических ошибок, является актуальной задачей. Предлагаемый метод предполагает сегментацию ультразвуковых изображений на сегменты заданного размера прямоугольной формы и соотнесение их к одному из трех классов: онкология, панкреатит, индифферентный класс. Классификация осуществляется за счет применения «сильных» и «слабых» классификаторов. Для «слабых» классификаторов при формировании дескрипторов используется преобразование Уолша-Адамара. Дескрипторы рассчитываются для трех «слабых» классификаторов. Для первого «слабого» классификатора используются спектральные коэффициенты преобразование Уолша-Адамара, вычисленные для окна всего сегмента. После дескрипторы вычисляются для других «слабых» классификаторов, которые представляют из себя окна, размеры которых в два и четыре раза меньше размеров исходного окна. Классификатор состоит из трех независимо обученных нейронных сетей – «слабых» классификаторов. Для объединения выходных данных нейронных сетей применяется усредняющий блок по ансамблю. Разработано программное обеспечение для классификации снимков УЗИ, которое позволяет формировать базу данных сегментов классов «онкология» и «панкреатит», определять двумерный спектр Уолша-Адамара сегментов снимка УЗИ, обучать полносвязные нейронные сети и проводить исследовательский анализ для изучения актуальности двумерных спектральных коэффициентов. Экспериментальные исследования по классификации снимков УЗИ, содержащих онкологию и панкреатит, показали среднее значение точности обнаружения онкологии – 88,4 %, а панкреатита – 85,7 %. Ошибки второго типа составляли в среднем 10,2 % при обнаружении панкреатита и 5,2 % при обнаружении онкологии. Для настройки и проверки классификаторов использовались реальные данные УЗИ поджелудочной железы.

Ключевые слова: УЗИ, поджелудочная железа, онкология, панкреатит, обнаружение заболевания, сегментация снимков УЗИ, нейронная сеть, классификация снимков УЗИ.

Для цитирования: Филист С.А., Кондрашов Д.С., Сухомлинов А.Ю., Шульга Л.В., Аль-Дарраджи Ч.Х., Белозёров В.А. Автоматизированная система классификации снимков УЗИ поджелудочной железы на основе метода посегментного спектрального анализа. *Моделирование, оптимизация и информационные технологии*. 2023;11(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1302> DOI: 10.26102/2310-6018/2023.40.1.021

Automated system for classifying pancreatic ultrasound images based on the segment-by-segment spectral analysis method

S.A. Filist¹✉, D.S. Kondrashov¹, A.Y. Sukhomlinov¹, L.V. Shulga¹, Ch.H. Al-Darraji^{1,2}, V.A. Belozero³

¹Southwest State University, Kursk, Russian Federation

²The University of Diyala, Baqubah, the Republic of Iraq

³Kursk Regional Multidisciplinary Clinical Hospital, Kursk, Russian Federation
sfilist@gmail.com✉

Abstract. Classification of ultrasound images is the prevailing tool in the diagnosis of many pancreas diseases. It takes years of experience and training for a doctor to interpret an ultrasound image. Therefore, the development of models, methods and algorithms for improving the reliability and quality of interpretation of ultrasound images through the use of specialized software tools that reduce the risk of diagnostic errors is a relevant issue. The proposed method involves the segmentation of ultrasound images into segments of prescribed size of a rectangular shape and their correlation to one of three classes: oncology, pancreatitis, indifferent class. Classification is carried out by means of "strong" and "weak" classifiers. For "weak" classifiers, the Walsh-Hadamard transform is employed in the formation of descriptors. Descriptors are calculated for three "weak" classifiers. For the first "weak" classifier, the spectral coefficients of the Walsh-Hadamard transform are used, calculated for the window of the entire segment. After that, the descriptors are calculated for other "weak" classifiers, which are windows with sizes that are two and four times smaller than the sizes of the original window. The classifier consists of three independently trained neural networks – "weak" classifiers. To combine the output data of neural networks, an averaging block over the ensemble is used. Software has been developed for classifying ultrasound images which helps to create a database for the "oncology" and "pancreatitis" class segments, determine the two-dimensional Walsh-Hadamard spectrum of ultrasound image segments, train fully connected neural networks and conduct exploratory analysis to study the relevance of two-dimensional spectral coefficients. Experimental studies on the classification of ultrasound images containing oncology and pancreatitis showed an average accuracy of oncology detection – 88.4 %, and pancreatitis – 85.7 %. Errors of the second type averaged 10.2 % when pancreatitis was detected and 5.2 % when oncology was detected. To set up and test the classifiers, real data from pancreatic ultrasound were used.

Keywords: ultrasound, pancreas, oncology, pancreatitis, disease detection, segmentation of ultrasound images, neural network, classification of ultrasound images.

For citation: Filist S.A., Kondrashov D.S., Sukhomlinov A.Y., Shulga L.V., Al-Darraji Ch.H., Belozero V.A. Automated system for classifying pancreatic ultrasound images based on the segment-by-segment spectral analysis method. *Modeling, Optimization and Information Technology*. 2023;11(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1302> DOI: 10.26102/2310-6018/2023.40.1.021 (In Russ.).

Введение

Ультразвуковая диагностика является одной из наиболее распространенных схем выявления заболеваний в клинической практике. У ультразвуковой визуализации есть много преимуществ, таких как безопасность, удобство и низкая стоимость. Однако для освоения врачом методики интерпретации ультразвукового изображения требуются годы подготовки и опыта. Для поддержки диагностики клиницистов и снижения нагрузки на врачей предлагается множество систем ультразвуковой компьютерной диагностики. В настоящее время разработаны различные методы, модели и алгоритмы для решения проблемы идентификации и классификации снимков УЗИ поджелудочной железы.

В [1] приводится метод диагностики очаговых образований поджелудочной железы (ПЖ) на основе искусственной нейронной сети. Авторы использовали программный анализ постобработки для вычисления отдельных кадров

эластографических видеоданных, записанных путем извлечения данных гистограммы оттенков из динамической последовательности эластографии в числовую матрицу. Затем данные были проанализированы с помощью расширенного нейросетевого анализа, чтобы автоматически отличать доброкачественные паттерны от злокачественных.

В [2] предложена система компьютерной диагностики с обработкой изображений и распознаванием образов для диагностики рака ПЖ с использованием анализа снимков УЗИ. В процессе диагностики выделялись области интереса трех групп пациентов по возрасту до 40 лет, от 40 до 60 и старше 60 лет; особенности были получены из изображений с использованием трех различных методов и были обучены отдельно для каждой возрастной группы с помощью искусственной нейронной сети для диагностики рака. Было отмечено, что система лучше справляется с диагностикой изображений рака ПЖ при разделении пациентов по возрасту.

В [3] представлено исследование, направленное на то, чтобы в режиме реального времени дифференцировать рак поджелудочной железы (РПЖ) или поражение, не связанное с раком поджелудочной железы (НРПЖ), с помощью анализа изображений эндоскопической ультрасонографии (ЭУЗИ). Перед обучением модели области интереса (ROI) были вручную выделены, чтобы отметить поражения РПЖ и НРПЖ. В качестве модели алгоритма для автоматического определения наличия поражения поджелудочной железы использовался архитектура YOLOv5. Это исследование показало, что YOLOv5m предоставляет хорошие результаты и обеспечивает поддержку принятия решений в режиме реального времени для разделения РПЖ или поражения НРП.

В [4] проведены исследования с набором данных эндоскопической ультразвуковой визуализации для обучения алгоритма СНС-ДНСКП для автоматической постановки диагноза в режиме реального времени. Модель сверточной нейронной сети (СНС) была разработана для того, чтобы дифференцировать визуальные особенности изображений хронического псевдоопухолевого панкреатита, нейроэндокринной опухоли и протоковой аденокарциномы. Кроме того была разработана сетевая модель долговременной нейронной сети с кратковременной памятью (ДНСКП) для учета динамики физических характеристик с течением времени. В качестве системы поддержки принятия клинических решений модели глубокого обучения улучшили дифференциально-диагностические возможности обнаружения морфологических образований на изображениях ПЖ.

В последние годы все большее количество ученых осознали, что повышение производительности и точности анализа медицинских изображений достигается за счет использования нейросетевых классификаторов изображений [5, 6, 7, 8, 9, 10, 11]. Поэтому для классификации снимков УЗИ ПЖ при диагностике заболеваний мы будем использовать полностью связанные нейронные сети, а для повышения эффективности классификации изображение предварительно сегментируется на прямоугольные сегменты одинакового размера и для каждого сегмента принимается решение о возможности наличия панкреатита или онкологии.

Методы и материалы

Классификатор снимков ПЖ, записанных с аппарата УЗИ, основан на концепции каскадного окна [12, 13, 14, 15], суть которой заключается в двухэтапной классификации: на первом этапе определяется только наличие интереса к данному изображению или сегменту (класс ROI или HE класс ROI), а на втором этапе принимается окончательное решение о принадлежности сегмента к определенному классу.

Согласно изложенному в [12, 13, 14] алгоритму классификации, процедура формирования сегментов изображения включает в себя следующие шаги: 1) вводится

пороговое значение яркости пикселей изображения и сам снимок; 2) определяется фон в исходном изображении; 3) снимок декомпозируется на четыре сегмента-потомка; 4) цикл выполняет поиск сегментов-потомков принадлежности к ROI согласно условию

$$\frac{S_i}{S} \geq T_{tr}, \quad (1)$$

где S_i – значение яркости фона в дочернем сегменте, S – значение яркости фона в родительском сегменте; 5) если среди этих потомков есть потомок ROI, то он переходит на второй уровень и также выполняется его декомпозиция на четыре потомка; 6) если для сегмента ROI на текущем уровне невозможно выполнить декомпозицию, то он возвращается на предыдущий уровень и попадает в множество сегментов класса ROI.

Пример декомпозиции изображения УЗИ ПЖ с онкологией показан на Рисунке 1. Изображение УЗИ декомпозируется на четыре сегмента в зависимости от геометрических размеров изображения, что выполняется на шаге 4 алгоритма. Затем для каждого из четырех полученных сегментов проверяется условие (1). На следующий уровень декомпозиции переходят только те сегменты, для которых выполняется условие (1). Это условие выполняется для сегмента № 1, 2. Они переходят на следующий уровень декомпозиции, где также делятся на четыре сегмента. На Рисунке 2 показан пример декомпозиции сегмента № 2 на следующем уровне.

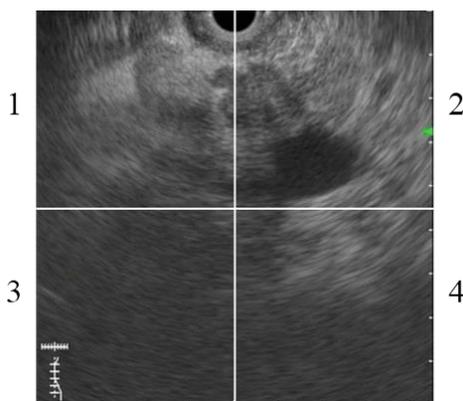


Рисунок 1 – Пример сегментации изображения на первом уровне декомпозиции
Figure 1–Example of image segmentation at the first level of decomposition

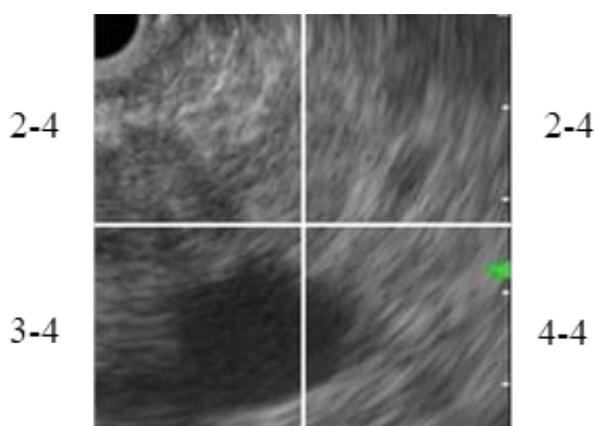


Рисунок 2 – Декомпозиция сегмента № 2 на втором уровне
Figure 2 – Decomposition of segment No. 2 at the second level

После декомпозиции сегмента проводится очередная проверка условия (1) с формированием подмножества сегментов класса ROI. При необходимости элементы этого подмножества можно комбинировать. Суть процедуры объединения сегментов заключается в том, что если сегменты класса ROI имеют общую границу, то ее можно устранить, и размер сегмента класса ROI увеличится по соответствующей координате. Процесс увеличения размера сегмента представлен в два этапа на Рисунке 3.

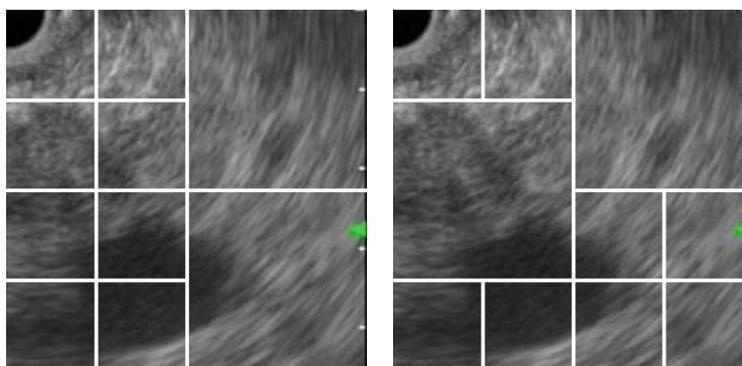


Рисунок 3 – Иллюстрация двух этапов увеличения размера сегмента
Figure 3 – Illustration of two stages of increasing the segment size

После получения набора сегментов класса ROI (область интереса), сегменты этого набора делятся на классы. Для решения задачи классификации сегментов класса ROI в данной работе используется технология бустинга, изложенная в [7]. Для формирования дескрипторов для «слабых» классификаторов использовалось преобразование Уолша-Адамара в многомасштабных окнах [8, 9, 11, 13].

Преобразование Уолша-Адамара рассчитывалось для окон трех масштабов, то есть дескрипторы формировались для трех «слабых» классификаторов [12]. Сначала преобразование Уолша-Адамара вычисляется для всего окна. Затем формируются окна, размер которых составляет половину размера исходного окна. Дескрипторы для второго «слабого» классификатора вычисляются по сегментам в этих окнах и так далее, а дескрипторы третьего «слабого» классификатора вычисляются по сегментам окон, полученным на предыдущем масштабе.

Суть этой классификации проиллюстрирована на Рисунке 4. Классификатор сегмента класса ROI использует многоуровневую иерархическую структуру, основанную на концепции «сильных» и «слабых» классификаторов. На Рисунке 5 показана структура со «слабыми» классификаторами, полученная на основе спектрального преобразования Уолша-Адамара в окнах трех стандартных размеров.

Сегмент класса ROI поступает на формирователь трех окон Уолша-Адамара, которые формируют одно окно размером 32x32 пикселя, четыре окна размером 16x16 пикселей и шестнадцать окон размером 8x8 пикселей из сегмента. Двумерные спектры Уолша-Адамара определяются в блоках двумерного преобразования Уолша (ДПУ) в окнах этих стандартных размеров. Спектральные коэффициенты, полученные в этих окнах, используются в качестве дескрипторов для соответствующих входных данных «слабых» классификаторов СК1...СК3, которые настраиваются независимо в соответствии с соответствующими обучающими образцами для двух классов «онкология» и «панкреатит» (кл. 1 и кл. 2). Их решения агрегируются с помощью «сильного» классификатора, реализованного по схеме многослойного персептрона [9, 12, 13, 16].

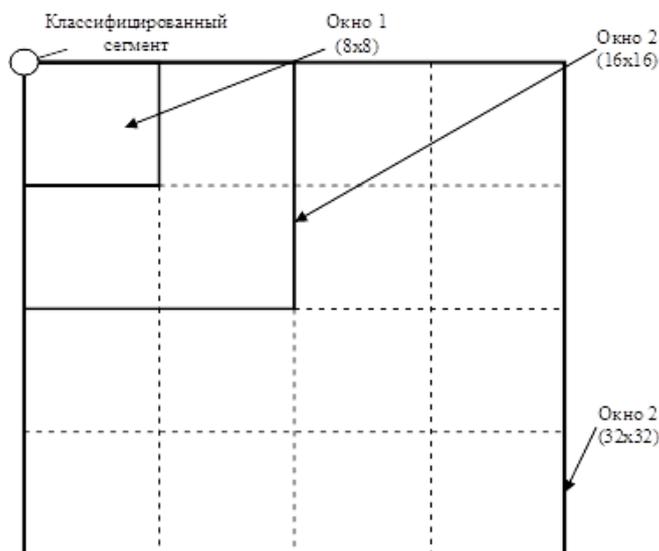


Рисунок 4 – Вложенные спектральные окна для классификации сегментов изображения
Figure 4 – Nested spectral windows for classifying image segments

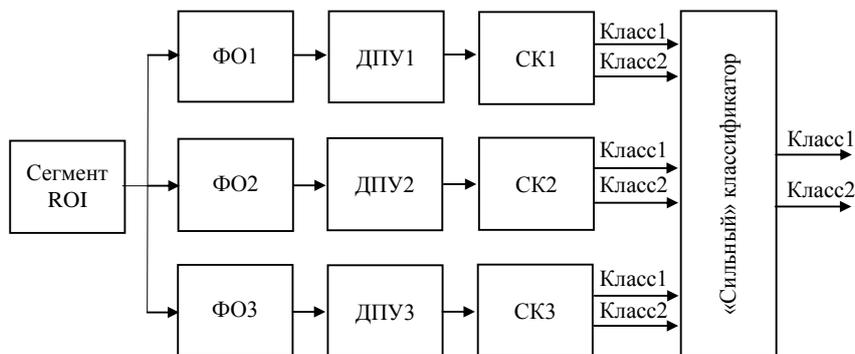


Рисунок 5 – Классификатор сегментов класса ROI с тремя размерами окон Уолша-Адамара: ФО – формирователь окон; ДПУ – двумерное преобразование Уолша; СК – слабый классификатор
Figure 5 – Classifier of ROI class segments with three Walsh-Hadamard window sizes: WS – window shaper; DWT – two-dimensional Walsh transform; WC – weak classifier

Коэффициенты Уолша-Адамара, поступающие с выхода блока ДПУ классификатора сегментов класса ROI, были разделены на «хранители» и «вершители». Спектральные коэффициенты, частота встречаемости которых является достаточно высокой в выборке определенного класса, были отнесены к «хранителям». Признаком того, что спектральный коэффициент является «хранителем», является то, что, когда он исключается из вектора дескрипторов, сегмент переходит в индифферентный класс. Таким образом, выбор «хранителей» может быть осуществлен только классификатором. Поскольку классификатор еще не построен на этапе отбора, в его роли выступает лицо, принимающее решения (ЛПР), то есть эксперт.

Схема алгоритма отбора «хранителей» показана на Рисунке 6. Чтобы выбрать «хранителя», необходимо просмотреть всю выборку сегментов данного класса в цикле. В каждом сегменте j -того класса определяется ДПУ. В блоках 5...9 определяется актуальность соответствующего спектрального коэффициента в текущем сегменте в этом классе. Используется селектор амплитудных коэффициентов (блок 5), который сбрасывает коэффициенты, модуль которых ниже определенного порогового значения.

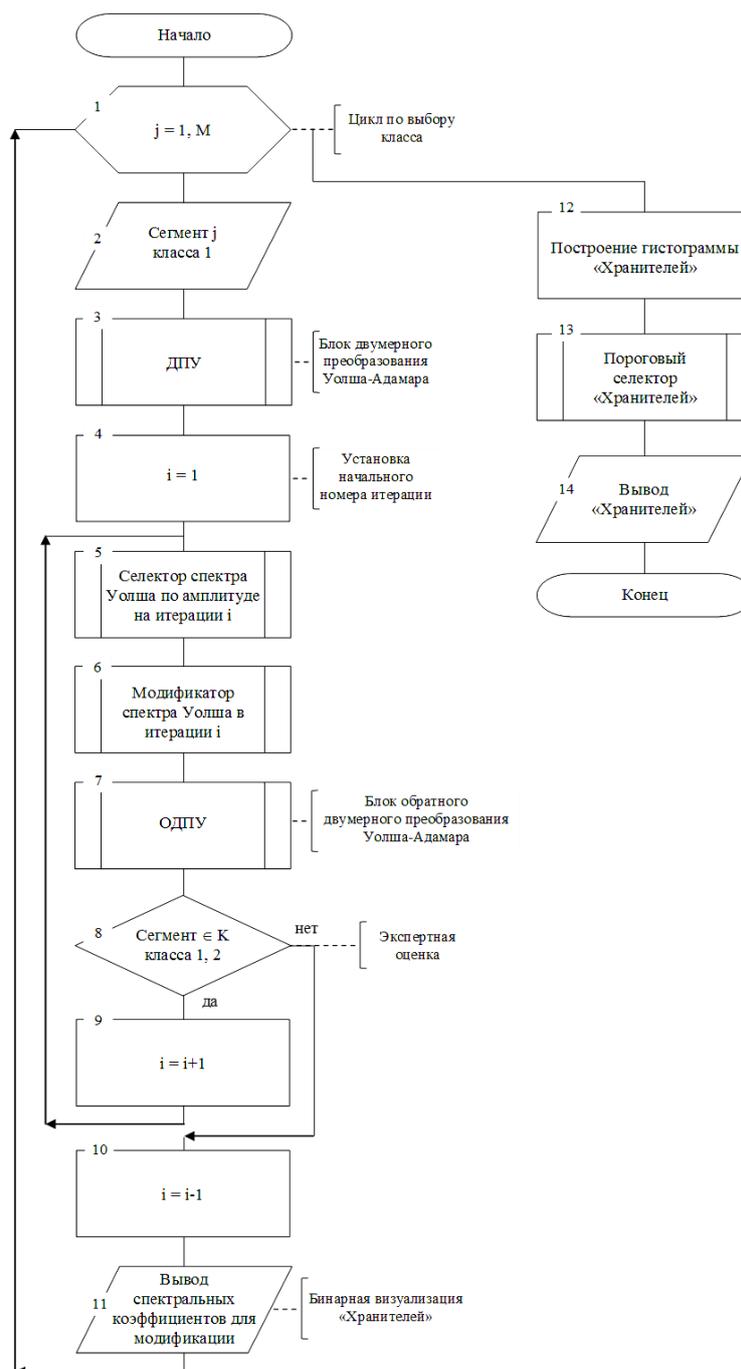


Рисунок 6 – Схема алгоритма отбора «хранителей»
Figure 6 – Diagram of the algorithm for selecting “keepers”

После обнуления коэффициентов в блоке 6 определяется обратное двумерное преобразование Уолша (ОДПУ) модифицированного спектра. Затем ЛПР определяет, принадлежит ли измененное изображение к заданному классу или оно попало в индифферентный класс. Если изображение, согласно ЛПР, сохранило характеристики исходного класса, то проводится дальнейшая модификация спектра. В противном случае формируется двоичное изображение, в котором спектральные коэффициенты, которые являются «хранителями» в этом сегменте, помечены единицами. После определения M двоичных изображений (блок 11) из них строится гистограмма частоты выпадения «хранителей» в данной выборке (блок 12).

Анализируя гистограмму, можно установить пороговое значение для частоты появления спектрального коэффициента в выборке этого класса. Спектральные коэффициенты с коэффициентом отсева ниже порогового значения удаляются из пула «хранителей». Однако такой подход не позволяет дать оценку специфичности спектральных коэффициентов, поскольку одни и те же спектральные коэффициенты могут одинаково часто встречаться в образцах альтернативных классов.

Спектральные коэффициенты «вершители» определяют элементы матрицы «вершителей». Матрица «вершителей» определяется по матрицам средних значений спектральных коэффициентов альтернативных классов. Ее элементы определяются как модули разности соответствующих спектральных коэффициентов матриц средних значений. Модули разности средних значений нормализуются на элементы одной из этих матриц. К «вершителям» относят те элементы матрицы, а следовательно, и соответствующие им спектральные коэффициенты, величина которых превышает определенное пороговое значение.

Спектральные коэффициенты, соответствующие «вершителям», будут вектором информативных признаков нейронной сети. Схема алгоритма выбора «вершителей» показана на Рисунке 7. Алгоритм работает с выборками двух классов размеров N и M. После определения их ДПУ (блок 2) мы получаем две выборки спектральных коэффициентов одинакового размера.

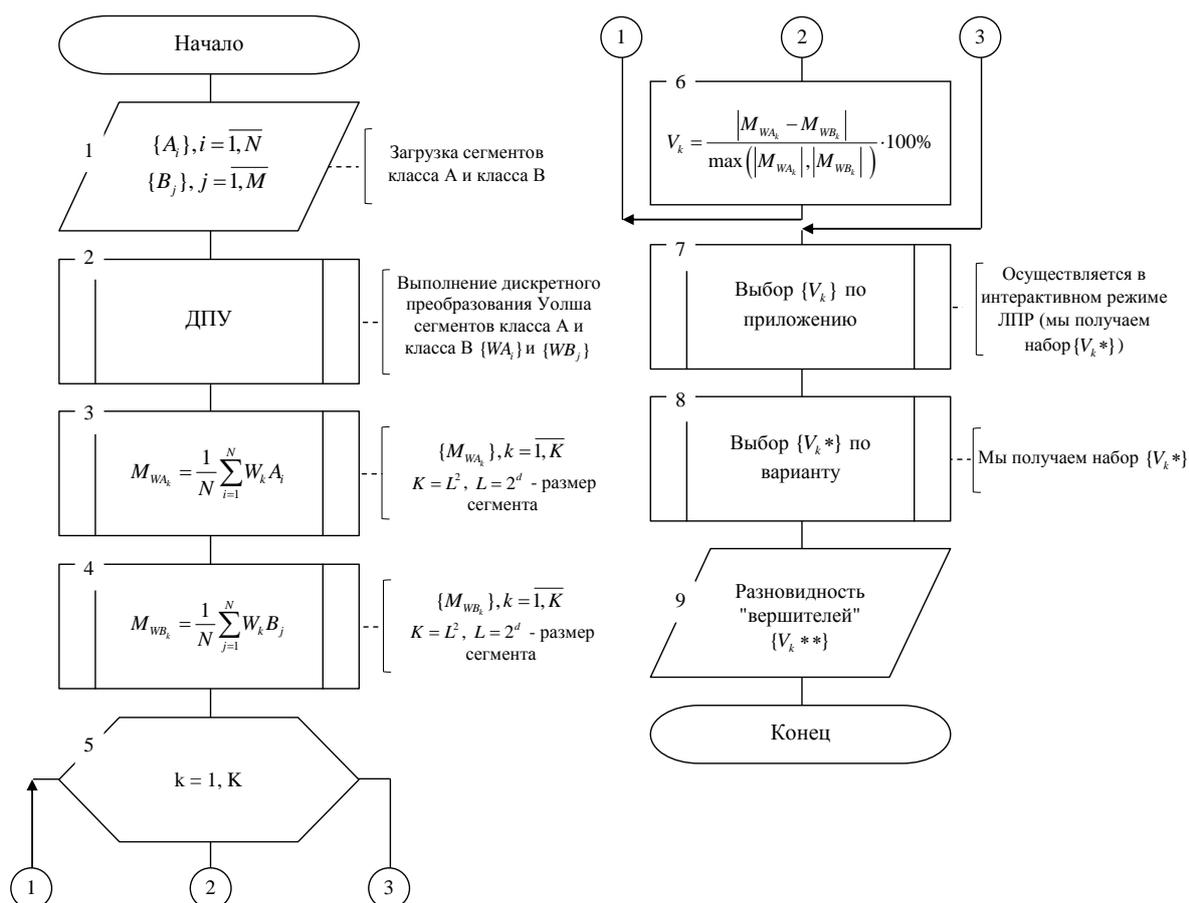


Рисунок 7 – Схема алгоритма выбора «вершителей»
Figure 7 – Diagram of the algorithm for selecting “verifiers”

Для коэффициентов в каждой выборке мы находим их математические ожидания (блоки 3 и 4).

$$M_{WA_k} = \frac{1}{N} \sum_{i=1}^N W_k A_i, \quad (2)$$

$$M_{WB_k} = \frac{1}{N} \sum_{j=1}^N W_k B_j, \quad (3)$$

где $W_k A_i$ – k -й коэффициент Уолша i -го сегмента из выборки класса А, $W_k B_j$ – k -й коэффициент Уолша j -го сегмента из выборки класса В.

Отбор «вершителей» по амплитуде (в процентах) осуществляется так же, как и «хранителей» (блок 7). Чтобы выбрать окончательный пул «вершителей», необходимо исследовать их изменчивость от сегмента к сегменту. Для этого для каждого «вершителя» определяется гистограмма для двух выборок. В зависимости от пересечения гистограмм ЛПП принимает окончательное решение о включении этого спектрального коэффициента в «вершители».

На Рисунке 8 показана блок-схема «слабого» классификатора, в котором «хранители» и «вершители» используются в качестве дескрипторов нейронных сетей. Из-за особенностей их формирования нейронные сети NET1 и NET2 разделяют сегмент на классы Класс 1 – НЕ Класс 1 и Класс 2 – НЕ Класс 2 соответственно. Нейронная сеть NET3 разделяет классы 1 и 2. В качестве агрегатора решений этих трех нейронных сетей может использоваться полностью связанная обучаемая нейронная сеть прямого распространения или модуль нечеткого принятия решений [5, 6, 7, 8, 9, 10].

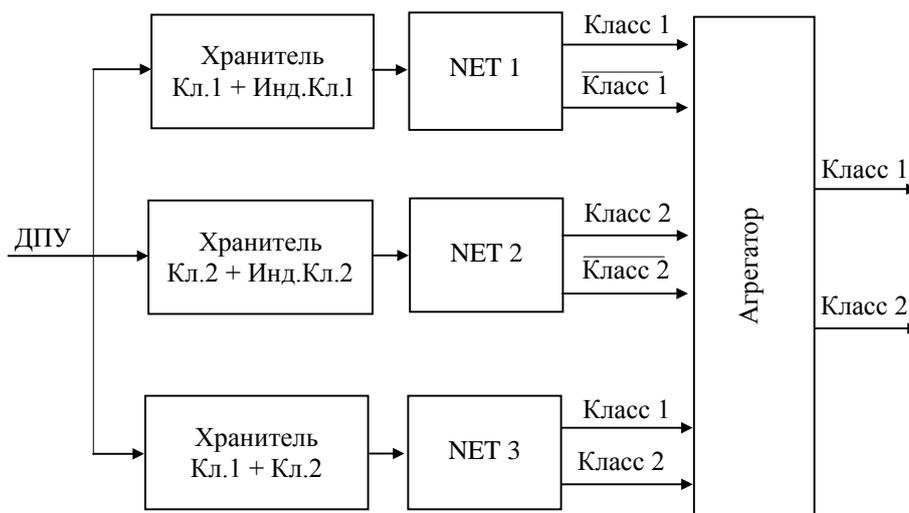


Рисунок 8 – Структурная схема «слабого» классификатора:
ДПУ – двумерное преобразование Уолша; Инд.Кл1 – индифферентный класс

Figure 8 – Block diagram of the “weak” classifier:
DWT – two-dimensional Walsh transform; Ind.Kl1 – indifferent class

Элементы матрицы «вершителей» находятся по формуле (блок 6):

$$V_k = \frac{|M_{WA_k} - M_{WB_k}|}{\max(|M_{WA_k}|, |M_{WB_k}|)} \cdot 100\%. \quad (4)$$

Для синтеза «слабых» классификаторов на спектральной плоскости было разработано программное обеспечение. Модульная структура программного

обеспечения показана на Рисунке 9. Программное обеспечение написано на Python 3.10 для Windows 7, 8, 10.



Рисунок 9 – Модульная структура программного обеспечения для построения «слабых» классификаторов

Figure 9 – Modular structure of software for building “weak” classifiers

Основой программного обеспечения является Контроллер задач, который взаимодействует с хранилищем данных – «Модель данных» (МД). Исходное изображение загружается с помощью сервиса ввода-вывода. На Рисунке 10 показан программный интерфейс для создания базы данных (БД) обучающих и контрольных выборок.

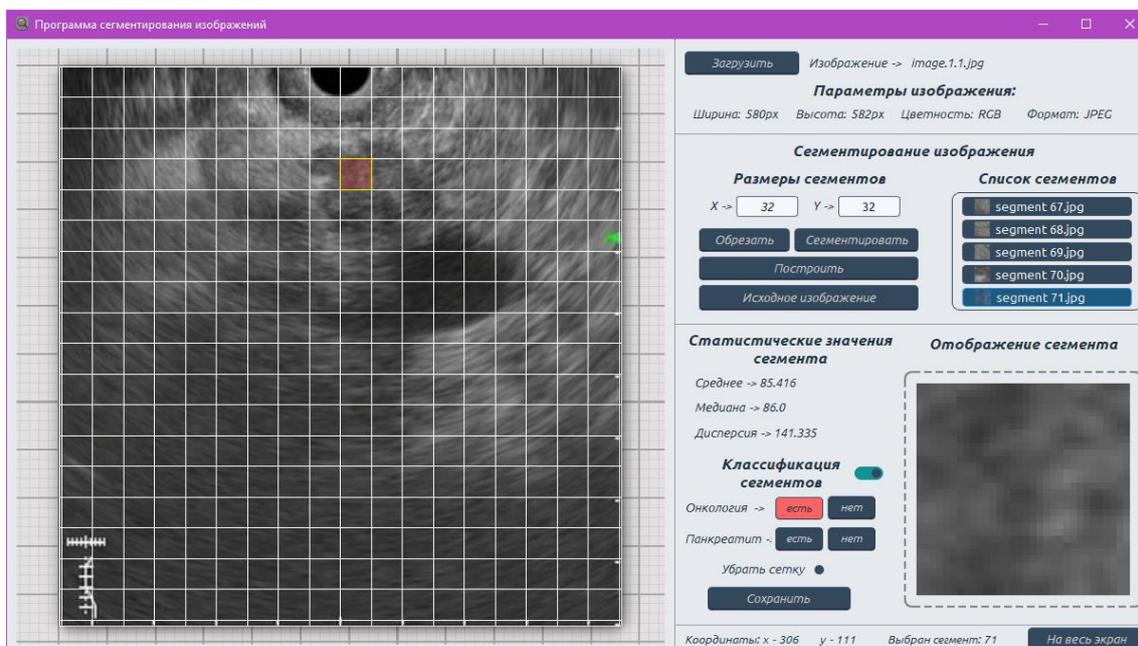


Рисунок 10 – Программный интерфейс для создания базы данных обучающих выборок

Figure 10 – Programming interface for creating a database of training samples

Исходное изображение разделено на сегменты квадратной формы с размерами, кратными двум. ЛПР устанавливает флаг индикатора класса (на Рисунке 10 это класс «онкология») и отмечает указателем мыши сегмент, который принадлежит этому классу. После окончания выделения сегментов к определенному классу, ЛПР нажимает кнопку «Сохранить» и отмеченные сегменты отправляются в папку базы данных, в которой хранятся сегменты этого класса.

Основные вычислительные процедуры реализуются следующими модулями принятия решений: модуль быстрого преобразования Уолша (БПУ); модуль формирования окна; модуль вычисления дескрипторов (информативных признаков); модуль для формирования решающих правил (синтез классификатора).

На Рисунке 11 показан вид окна интерфейса, когда модуль анализа сегментов работает с сегментом класса «онкология». Левая часть окна содержит фрагмент базы данных моментальных снимков этого класса. Пользователь может выбрать любой интересующий его сегмент и просмотреть его изображение в оттенках серого (представленное в верхней центральной части окна). В дальнейшем мы работаем только с полутоновыми изображениями.

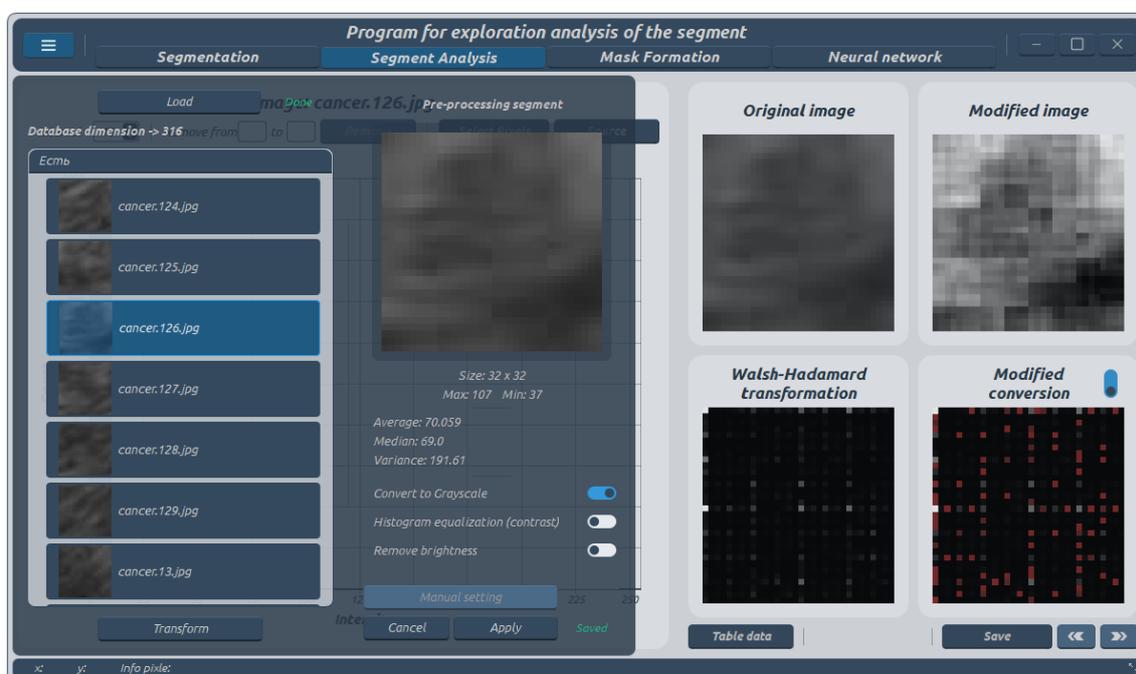


Рисунок 11 – Изображение интерфейса поддержки программного обеспечения
 Figure 11 – Image of the software support interface

Кнопка «Transform» в левом нижнем углу окна позволяет рассчитать преобразование Уолша-Адамара выбранного сегмента (сегмента, изображение которого расположено в центральной части окна). В правой части окна есть четыре изображения. Первое изображение, «Source Image», является копией изображения сегмента в центральной части окна. Изображение «Walsh-Hadamard transformation» представляет собой представление спектра Уолша-Адамара исходного сегмента в оттенках серого, а изображение «Modified conversion» представляет собой представление спектра Уолша-Адамара с выделенными пикселями красного цвета, которые по усмотрению пользователя не являются информативно значимыми и не будут использоваться при формировании вектора информативных признаков. Изображение «Modified image» получается путем обратного преобразования Уолша-Адамара, представленного в изображении «Modified conversion». Поскольку спектральные коэффициенты могут

принимать как отрицательные, так и положительные значения, их полутоновые коды отображают их абсолютные значения.

Например, на Рисунке 12 показано окно размером 32x32 пикселя (б), содержащее сегмент изображения класса «онкология». Соответствующий спектр Уолша-Адамара этого фрагмента показан на Рисунке 12 (в). На Рисунке 13 показано окно сегмента размером 32x32 пикселя (б), содержащее сегмент того же изображения (а) индифферентного класса, который соответствует спектру Уолша-Адамара на Рисунке (в).

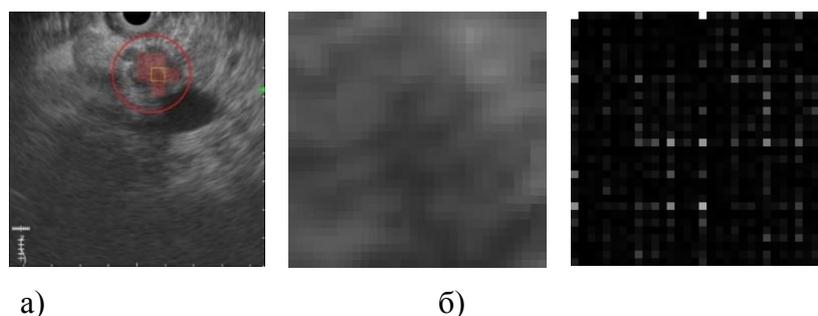


Рисунок 12 – а) Изображение УЗИ поджелудочной железы с отображением дислокации сегмента класса "онкология"; б) выделенный сегмент класса "онкология"; в) двумерный спектр Уолша-Адамара выделенного сегмента

Figure 12 – a) Ultrasound image of the pancreas showing the dislocation of the "oncology" class segment; b) the selected "oncology" class segment; c) two-dimensional Walsh-Hadamard spectrum of the selected segment

На Рисунке 13 показано окно сегмента размером 32x32 пикселя (б), содержащее сегмент того же изображения (а) индифферентного класса, который соответствует спектру Уолша-Адамара на рисунке (с).

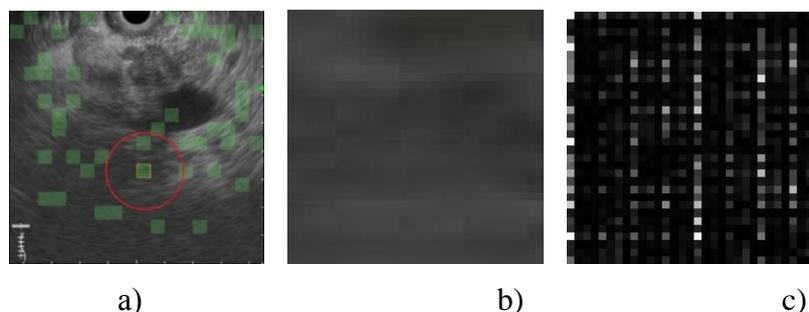


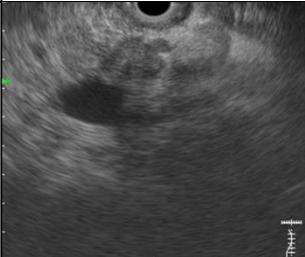
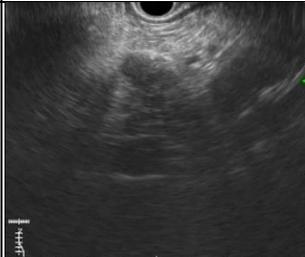
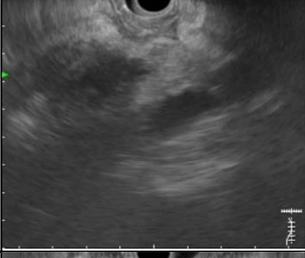
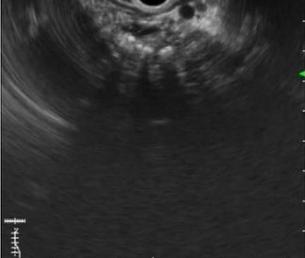
Рисунок 13 – а) Изображение УЗИ поджелудочной железы с отображением дислокации сегмента индифферентного класса; б) выделенный сегмент индифферентного класса; в) двумерный спектр Уолша-Адамара выделенного сегмента

Figure 13 – a) Ultrasound image of the pancreas showing the dislocation of indifferent class segment; b) the selected segment of the indifferent class; c) the two-dimensional Walsh-Hadamard spectrum of the selected segment

Результаты

Для экспериментальных исследований использовались видеопоследовательности УЗИ ПЖ, предоставленные врачом-эндоскопистом. Кадры некоторых использованных изображений из видеоматериалов и их свойства показаны в Таблице 1.

Таблица 1 – Примеры тестовых снимков из базы данных
Table 1 – Examples of test images from the database

Описание тестового видеоряда	Образец кадра	Описание тестового видеоряда	Образец кадра
Database\image.1.1 Разрешение: 600x600		Database\image.30.1 Разрешение: 600x600	
Database\image.4.1 Разрешение: 600x600		Database\image.35.1 Разрешение: 600x600	
Database\image.7.1 Разрешение: 600x600		Database\image.40.1 Разрешение: 600x600	
Database\image.14.1 Разрешение: 600x600		Database\image.42.1 Разрешение: 600x600	
Database\image.23.1 Разрешение, пиксели: 600x600		Database\image.43.1 Разрешение, пиксели: 600x600	

Целью экспериментальных исследований был анализ показателей качества классификации классификаторов изображений с сегментами класса «онкология» и «панкреатит». В этом случае онкология или панкреатит считались обнаруженными, если на изображении УЗИ поджелудочной железы был обнаружен хотя бы один желаемый сегмент класса «онкология» или «панкреатит». Обучающая выборка видеоизображений (кадров видеопоследовательностей) включает в себя 200 примеров. Количество сегментов класса «онкология» в обучающем наборе составило 316, для класса «панкреатит» – 576, для индифферентного класса – 1242.

Для оценки качества предлагаемого метода использовались следующие показатели: точность (Т) – отношение сегментов, класс которых определен правильно, к общему количеству классифицированных сегментов; чувствительность (Ч) – отношение правильно классифицированных сегментов данного класса к общему числу сегментов этого класса в контрольной выборке; специфичность (СП) – отношение правильно классифицированных сегментов индифферентного класса к общему числу сегментов этого класса в контрольной выборке.

В Таблице 2 приведены результаты экспериментальных исследований показателей качества классификации двух классов: «онкология»

Таблица 2 – Показатели эффективности метода для класса «онкология»

Table 2 – Efficiency indicators of the method for the “oncology” class

Класс	Чувствительность, %	Специфичность, %	Точность, %	Количество сегментов
Онкология	88,4	94,8	90,1	316
Индифферентный	93	91		501

В Таблице 3 приведены результаты экспериментальных исследований показателей качества классификации при обнаружении панкреатита в сегментах изображений УЗИ. Как и в случае обнаружения онкологии, сегменты снимков видеоматериала делятся на две группы: сегменты с панкреатитом и без панкреатита (класс безразличия).

Таблица 3 – Показатели эффективности метода для класса «панкреатит»

Table 3 – Efficiency indicators of the method for the “pancreatitis” class

Класс	Чувствительность, %	Специфичность, %	Точность, %	Количество сегментов
Панкреатит	85,7	89,8	88,7	576
Индифферентный	84,4	87,1		741

Критерием достоверности классификации считался результат изучения изображения УЗИ поджелудочной железы, проведенного двумя лицами, принимающими решения.

Заключение

1. Разработана автоматизированная система для классификации снимков УЗИ поджелудочной железы. Автоматизированная система включает совокупность программных модулей для реализации технологических операций классификации снимков УЗИ поджелудочной железы, а также аннотированную базу данных снимков УЗИ поджелудочной железы без патологических изменений и с поставленными диагнозами панкреатит и онкология.

2. Процедура классификации снимков УЗИ включает два этапа. На первом этапе на снимке выделяются области (сегменты) ROI. На втором этапе используется метод многомасштабных окон, согласно которому области ROI делятся на многомасштабные окна, в окне каждого масштаба определяются дескрипторы для «слабых» классификаторов, по анализу которых «слабые» классификаторы принимают решение об отнесении окна соответствующего масштаба к соответствующему классу, после чего «сильный» классификатор осуществляет агрегацию этих решений.

3. Для вычисления информативных признаков было предложено использовать двумерное преобразование Уолша-Адамара в окнах соответствующих масштабов.

4. В качестве классификаторов многомасштабных окон предложено использовать полносвязные нейронные сети, входные векторы которых формировались путем дискриминации спектральных коэффициентов Уолша-Адамара на «хранители» и «вершители».

5. Разработано программное обеспечение для формирования базы данных снимков УЗИ поджелудочной железы для обучения нейросетевых классификаторов, а также для формирования дескрипторов для «слабых» и «сильных» классификаторов.

6. По выбранным показателям качества классификации снимков УЗИ поджелудочной железы были протестированы различные модели классификаторов для различения сегментов класса «онкология», класса «панкреатит» и сегментов индифферентного класса, которые показали среднее значение диагностической чувствительности при обнаружении онкологии на снимках УЗИ поджелудочной железы 88,4 %, а панкреатита – 85,7 %. Диагностическая специфичность составляла в среднем 89,8 % при обнаружении панкреатита и 94,8 % при обнаружении онкологии. Достигнутые показатели качества классификации снимков УЗИ поджелудочной железы позволяют рекомендовать предложенную автоматизированную систему для использования в системах поддержки принятия решений врача ультразвуковой диагностики.

СПИСОК ИСТОЧНИКОВ

1. Săftoiu A., Vilman P., Gorunescu F., Janssen J., Hocke M., Larsen M., Iglesias-Garcia J., Arcidiacono P., Will U., Giovannini M., Dietrich CF., Havre R., Gheorghe C., McKay C., Gheonea DI., Ciurea T. Efficacy of an artificial neural network-based approach to endoscopic ultrasound elastography in diagnosis of focal pancreatic masses. *Clinical Gastroenterology and Hepatology: the Official Clinical Practice Journal of the American Gastroenterological Association*. 2012;10(1):84–90. DOI: 10.1016/j.cgh.2011.09.014.
2. Ozkan M., Cakiroglu M., Kocaman O., Kurt M., Yilmaz B., Can G., Korkmaz U., Dandil E., Eksi Z. Age-based computer-aided diagnosis approach for pancreatic cancer on endoscopic ultrasound images. *Endoscopic Ultrasound*. 2016;5(2):101. DOI: 10.4103/2303-9027.180473.
3. Tian G., Xu D., He Y., Chai W., Deng Z., Cheng C., Jin X., Wei G., Zhao Q., Jiang T. Deep learning for real-time auxiliary diagnosis of pancreatic cancer in endoscopic ultrasonography. *Frontiers in Oncology*. 2022;12:973652. DOI: 10.3389/fonc.2022.973652.
4. Udriștoiu A.L., Cazacu I.M., Gruionu L.G., Gruionu G., Iacob A.V., Burtea D.E., Ungureanu B.S., Costache M.I., Constantin A., Popescu C.F., Udriștoiu Ș., Săftoiu A. Real-time computer-aided diagnosis of focal pancreatic masses from endoscopic ultrasound imaging based on a hybrid convolutional and long short-term memory neural network model. *PloS one*. 2021;16(6):e0251701. DOI: 10.1371/journal.pone.0251701.
5. Филист С.А., Томакова Р.А., Брежнева А.Н., Малютина И.А., Алексеев В.А. Клеточные процессоры в классификаторах многоканальных изображений. *Радиопромышленность*. 2019;(1):45–52.
6. Филист С.А., Томакова Р.А., Шаталова О.В., Кузьмин А.А., Али Кассим К.Д. Метод классификации сложноструктурируемых изображений на основе самоорганизующихся нейросетевых структур. *Радиопромышленность*. 2016;4:57–65.
7. Кудрявцев П.С., Кузьмин А.А., Филист С.А. Развитие методологии бустинга для классификации флюорограмм грудной клетки. *Биомедицинская радиоэлектроника*. 2016;9:10–15.

8. Белых В.С., Ефремов М.А., Филист С.А. Разработка и исследование метода и алгоритмов для интеллектуальных систем классификации сложноструктурируемых изображений. *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2016;(2):12–24.
9. Дюдин М.В., Кудрявцев П.С., Подмастерьев К.В., Филист С.А., Шаталова О.В. Математические модели для интеллектуальных систем классификации рентгенограмм грудной клетки. *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2016;(2):94–107.
10. Filist S.A., Tomakova R.A., Degtyarev S.V., Rybochkin A.F. Hybrid intelligent models for chest X-ray image segmentation. *Biomedical Engineering*. 2018;51(5):358–363. DOI: 10.1007/s10527-018-9748-5.
11. Dabagov A.R., Gorbunov V.A., Filist S.A., Maljutina I.A., Kondrashov D.S. An Automated System for Classification of Radiographs of the Breast. *Biomedical Engineering*. 2020;53(6): 425–428. DOI: 10.1007/s10527-020-09957-7.
12. Кудрявцев П.С., Кузьмин А.А., Савинов Д.Ю., Филист, С.А., Шаталова О.В. Моделирование морфологических образований на рентгенограммах грудной клетки в интеллектуальных диагностических системах медицинского назначения. *Прикаспийский журнал: управление и высокие технологии*. 2017;(3):109–120.
13. Филист С.А., Али Кассим К.Д., Кузьмин А.А., Шаталова О.В., Алябьев Е.А. Формирование признакового пространства для задач классификации сложноструктурируемых изображений на основе спектральных окон и нейросетевых структур. *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2016;(4):56–68.
14. Филист С.А., Дабагов А.Р., Томакова Р.А., Малютин И.А., Кондрашов Д.С. Метод каскадной сегментации рентгенограмм молочной железы. *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2019;9(1):49–61.
15. Филист С.А., Дабагов А.Р., Томакова Р.А., Малютин И.А., Кондрашов Д.С. Многослойные морфологические операторы для сегментации сложноструктурируемых растровых полутоновых изображений. *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. 2019;9(3):44–63.
16. Томакова Р.А., Филист С.А., Дураков И.В. Программное обеспечение автоматической классификации рентгенограмм грудной клетки на основе гибридных классификаторов. *Экология человека*. 2018;(6):59–64.

REFERENCES

1. Săftoiu A., Vilmann P., Gorunescu F., Janssen J., Hocke M., Larsen M., Iglesias-Garcia J., Arcidiacono P., Will U., Giovannini M., Dietrich CF., Havre R., Gheorghe C., McKay C., Gheonea DI., Ciurea T. Efficacy of an artificial neural network-based approach to endoscopic ultrasound elastography in diagnosis of focal pancreatic masses. *Clinical Gastroenterology and Hepatology: the Official Clinical Practice Journal of the American Gastroenterological Association*. 2012;10(1):84–90. DOI: 10.1016/j.cgh.2011.09.014.
2. Ozkan M., Cakiroglu M., Kocaman O., Kurt M., Yilmaz B., Can G., Korkmaz U., Dandil E., Eksi Z. Age-based computer-aided diagnosis approach for pancreatic cancer on

- endoscopic ultrasound images. *Endoscopic Ultrasound*. 2016;5(2):101. DOI: 10.4103/2303-9027.180473.
3. Tian G., Xu D., He Y., Chai W., Deng Z., Cheng C., Jin X., Wei G., Zhao Q., Jiang T. Deep learning for real-time auxiliary diagnosis of pancreatic cancer in endoscopic ultrasonography. *Frontiers in Oncology*. 2022;12:973652. DOI: 10.3389/fonc.2022.973652.
 4. Udriștoiu A.L., Cazacu I.M., Gruionu L.G., Gruionu G., Iacob A.V., Burtea D.E., Ungureanu B.S., Costache M.I., Constantin A., Popescu C.F., Udriștoiu Ș., Săftoiu A. Real-time computer-aided diagnosis of focal pancreatic masses from endoscopic ultrasound imaging based on a hybrid convolutional and long short-term memory neural network model. *PloS one*. 2021;16(6):e0251701. DOI: 10.1371/journal.pone.0251701.
 5. Filist S.A., Tomakova R.A., Brezhneva A.N., Malyutina I.A., Alekseev V.A. Cellular processors in multichannel image classifiers. *Radiopromyshlennost' = Radio industry*. 2019;(1):45–52. (In Russ.).
 6. Filist S.A., Tomakova R.A., Shatalova O.V., Kuz'min A.A., Ali Kassim K.D. Method of classification of complex structured images based on self-organizing neural network structures. *Radiopromyshlennost' = Radio industry*. 2016;4:57–65. (In Russ.).
 7. Kudryavtsev P.S., Kuz'min A.A., Filist S.A. Development of boosting methodology for classification of chest fluorograms. *Biomeditsinskaya radioelektronika = Biomedical radioelectronic*. 2016;9:10–15. (In Russ.).
 8. Belykh V.S., Efremov M.A., Filist S.A. Development and research of a method and algorithms for intelligent classification systems of complex structured images. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the South-West State University. Series: Control, computer engineering, information science. medical instruments engineering*. 2016;(2):12–24. (In Russ.).
 9. Dyudin M.V., Kudryavtsev P.S., Podmaster'ev K.V., Filist S.A., Shatalova O.V. Mathematical models for intelligent classification systems of chest radiographs. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the South-West State University. Series: Control, computer engineering, information science. medical instruments engineering* 2016;(2):94–107. (In Russ.).
 10. Filist S.A., Tomakova R.A., Degtyarev S.V., Rybochkin A.F. Hybrid intelligent models for chest X-ray image segmentation. *Biomedical Engineering*. 2018;51(5):358–363. DOI: 10.1007/s10527-018-9748-5.
 11. Dabagov A.R., Gorbunov V.A., Filist S.A., Malyutina I.A., Kondrashov D.S. An Automated System for Classification of Radiographs of the Breast. *Biomedical Engineering*. 2020;53(6): 425–428. DOI: 10.1007/s10527-020-09957-7.
 12. Kudryavtsev P.S., Kuz'min A.A., Savinov D.Yu., Filist, S.A., Shatalova O.V. Modeling of morphological formations on chest radiographs in intelligent diagnostic systems for medical purposes. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian journal: management and high technologies*. 2017;(3):109–120. (In Russ.).
 13. Filist S.A., Ali Kassim K.D., Kuz'min A.A., Shatalova O.V., Alyab'ev E.A. Formation of a feature space for classification problems of complex structured images based on spectral windows and neural network structures. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the South-West State University. Series: Control, computer engineering, information science. medical instruments engineering*. 2016;(4):56–68. (In Russ.).

14. Filist S.A., Dabagov A.R., Tomakova R.A., Malyutina I.A., Kondrashov D.S. Method of cascade segmentation of breast radiographs. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the South-West State University. Series: Control, computer engineering, information science. medical instruments engineering.* 2019;9(1):49–61. (In Russ.).
15. Filist S.A., Dabagov A.R., Tomakova R.A., Malyutina I.A., Kondrashov D.S. Multilayer morphological operators for segmentation of complex structured raster halftone images. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the South-West State University. Series: Control, computer engineering, information science. medical instruments engineering.* 2019;9(3):44–63. (In Russ.).
16. Tomakova R.A., Filist S.A., Durakov I.V. Software for automatic classification of chest radiographs based on hybrid classifiers. *Ekologiya cheloveka = Human ecology.* 2018;(6):59–64. (In Russ.).

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Филист Сергей Алексеевич, доктор технических наук, профессор, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, Курск, Российская Федерация.

e-mail: sfilist@gmail.com

ORCID: [0000-0003-1358-671X](https://orcid.org/0000-0003-1358-671X)

Sergey Alekseevich Filist, Doctor of Technical Sciences, Professor, Professor at the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation.

Кондрашов Дмитрий Сергеевич, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, Курск, Российская Федерация.

e-mail: kondrashov012@mail.ru

Dmitry Sergeevich Kondrashov, Postgraduate Student, the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation.

Сухомлинов Артем Юрьевич, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, Курск, Российская Федерация.

e-mail: ar.sykhomlinov@gmail.com

Artem Yurievich Sukhomlinov, Postgraduate Student, Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation.

Шульга Леонид Васильевич, доктор медицинских наук, профессор, профессор кафедры охраны труда и окружающей среды, Юго-Западный государственный университет, Курск, Российская Федерация.

e-mail: sfilist@gmail.com

ORCID: [0000-0002-6793-7362](https://orcid.org/0000-0002-6793-7362)

Leonid Vasilievich Shulga, Doctor of Medical Sciences, Professor, Professor at the Department of Occupational Safety and Environment, Southwest State University, Kursk, Russian Federation

Аль-Дарраджи Часиб Хасан, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, Курск, Российская Федерация; преподаватель Университета Дияла, Баакубу, Республика Ирак.

e-mail: chasibaboody@gmail.com

Chasib Hasan Al-Darraji, Postgraduate Student, Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation; Lecturer at the University of Diyala, Baqubah, the Republic of Iraq.

Белозёров Владимир Анатольевич, Vladimir Anatolyevich Belozarov, Candidate of Medical Sciences, Endoscopist, Kursk Regional Multidisciplinary Clinical Hospital, Kursk, Russian Federation.
e-mail: b9102107495@yandex.ru

Статья поступила в редакцию 30.12.2022; одобрена после рецензирования 15.02.2023; принята к публикации 06.03.2023.

The article was submitted 30.12.2022; approved after reviewing 15.02.2023; accepted for publication 06.03.2023.