

<https://doi.org/10.21869/2223-1536-2024-14-3-121-143>



УДК 621.391.26

Мультимодальный классификатор медицинского риска на основе многоэлектродного биоимпедансного преобразователя

А. В. Серебровский¹, Н. А. Корсунский¹, А. В. Лях¹, В. Н. Мишустин²,
О. В. Шаталова¹✉, Л. В. Шульга¹

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

² Курский государственный медицинский университет
Министерства здравоохранения Российской Федерации
ул. К. Маркса, д. 3, г. Курск 305041, Российская Федерация

✉ e-mail: Shatolg@mail.ru

Резюме

Цель исследования. Отечественные и зарубежные исследования доказали, что злокачественные опухоли молочной железы имеют значительно отличающийся импеданс от нормальных тканей. Однако биоимпедансный анализ имеет ограничения в разрешающей способности, а также в несовершенстве моделей биоимпеданса, необходимых для формирования входных векторов для систем машинного обучения.

Методы. В представленном исследовании предложен мультимодальный классификатор, сырые данные для которого получают посредством матрицы электродов. Он также имеет три канала обработки результатов биоимпедансного анализа, с последующей агрегацией их решений. Предложена импедансная модель биоматериала, позволяющая формировать дескрипторы для классификаторов медицинского риска.

Результаты. Разработаны аппаратно-программные средства для биоимпедансных исследований, которые включают устройство сбора данных для биоимпедансной спектроскопии на основе электродной матрицы, устройство связи с объектом исследования и устройство для спектроскопии биоимпеданса посредством матрицы электродов. Программные средства включают интерфейсные окна для настройки программы биоимпедансных исследований и обучения и тестирования полносвязных нейронных сетей. Проведены экспериментальное исследование мультимодального классификатора на физической модели с использованием включений большей проводимости (имитация опухоли) различных типов и размеров в диапазоне проводимости от 1,1 до 1,9 от фоновой. На основе полученных изображений в двухуровневой нейронной сети первого канала определялся интегральный риск рака молочной железы по всем пикселям изображения. Статистические исследования (ROC-анализ) показали достаточную для скринингового метода чувствительность и специфичность – >0,75.

Заключение. Таким образом, создана новая модель интеллектуальной поддержки принятия врачебных решений, интегрирующая возможности спектроскопии биоимпеданса, сверточных нейронных сетей и экспертного оценивания изображений, формируемых посредством биоимпедансного картирования. Однако современные данные, подтверждающие возможность разделения доброкачественных и злокачественных опухолей молочной железы с помощью методов биоимпедансометрии, весьма ограничены, что требует проведения дальнейших исследований в этом направлении.

Ключевые слова: рак молочной железы; биоимпедансная спектроскопия; многозвенная модель биоимпеданса; мультимодальный классификатор; дескрипторы; нейронная сеть; алгоритм.

Финансирование: Работа выполнена в рамках реализации программы развития ФГБОУ ВО «Юго-Западный государственный университет» программы стратегического академического лидерства «Приоритет-2030».

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Мультимодальный классификатор медицинского риска на основе многоэлектродного биоимпедансного преобразователя / А. В. Серебровский, Н. А. Корсунский, А. В. Лях, В. Н. Мишустин, О. В. Шаталова, Л. В. Шульга // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 3. С.121–143. <https://doi.org/10.21869/2223-1536-2024-14-3-121-143>

Поступила в редакцию 15.07.2024

Подписана в печать 11.08.2024

Опубликована 30.09.2024

Multimodal classifier of medical risk based on a multielectrode bioimpedance converter

Andrey V. Serebrovsky¹, Nikita A. Korsunskii¹, Anton V. Lyakh¹,
Vladimir N. Mishustin², Olga V. Shatalova¹ ✉, Leonid V. Shulga¹

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

² Kursk State Medical University of the Ministry of Health of the Russian Federation
3 Karl Marx Str., Kursk 305041, Russian Federation

✉ e-mail: Shatolg@mail.ru

Abstract

The purpose of the research. The aim of the study is Russian and foreign studies have shown that malignant breast tumors have significantly different impedance from normal tissues. However, bioimpedance analysis has limitations in resolution, as well as in the imperfection of bioimpedance models required to generate input vectors for machine learning systems.

Methods. The presented study proposes a multimodal classifier, the raw data for which are obtained through an electrode matrix. It also has three channels for processing the results of bioimpedance analysis, with subsequent aggregation of their solutions. An impedance model of biomaterial is proposed, which allows forming descriptors for medical risk classifiers.

Results. Hardware and software for bioimpedance studies have been developed, which include a data collection device for bioimpedance spectroscopy based on an electrode matrix, a device for communication with the object of study, and a device for bioimpedance spectroscopy using an electrode matrix. The software includes interface windows for setting up the bioimpedance research program and training and testing fully connected neural networks. An experimental study of the multimodal classifier on a physical model was conducted using inclusions of higher conductivity (tumor imitation) of various types and sizes in the conductivity range from 1.1 to 1.9 of the background. Based on the obtained images in the two-level neural network of the first channel, the integral risk of breast cancer was determined for all pixels of the image. Statistical studies (ROC analysis) showed sufficient sensitivity and specificity for the screening method - > 0.75.

Conclusion. Thus, a new model of intelligent support for medical decision-making has been created, integrating the capabilities of bioimpedance spectroscopy, convolutional neural networks and expert assessment of images generated by bioimpedance mapping. However, current data confirming the possibility of separating benign and malignant breast tumors using bioimpedancemetry methods are very limited, which requires further research in this direction.

Keywords: breast cancer; bioimpedance spectroscopy; multi-tier bioimpedance model; multimodal classifier; descriptors; neural network; algorithm.

Financing: The work was carried out within the framework of the implementation of the program for the development of the Federal State Budgetary Educational Institution of Higher Education "Southwestern State University" of the strategic academic leadership program "Priority 2030".

Conflict of interest: The Authors declares the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Serebrovsky A.V., Korsunskii N.A., Lyakh A.V., Mishustin V.N., Shatalova O.V., Shulga L.V. Multimodal classifier of medical risk based on a multielectrode bioimpedance converter. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(3):121–143. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-3-121-143>

Received 15.07.2024

Accepted 11.08.2024

Published 30.09.2024

Введение

Рак молочной железы (РМЖ) является наиболее распространенной злокачественной опухолью среди женщин. Раннее выявление РМЖ играет ведущую роль в снижении уровня смертности [1]. В настоящее время рентгеновская маммография является стандартным методом скрининга для выявления РМЖ [2]. Однако она имеет ряд ограничений, включая снижение способности выявлять карциному у женщин с плотной тканью молочной железы (МЖ) [3].

В последнее время использование методов биоимпедансного анализа для обнаружения РМЖ стало новым направлением¹, поскольку было найдено больше доказательств того, что злокачественные опухоли МЖ имеют значительно отличающийся импеданс от нормальных тканей [4]. Электрический импеданс можно использовать для разделения доброкачественных и злокачественных опухолей и, следовательно, уменьшить количество доброкачественных

биопсий [3]. Однако существует ряд проблем, которые ограничивают их клиническое применение, включая выявление РМЖ [4]. Ключевым ограничением биоимпедансных методов диагностики РМЖ является их низкое пространственное разрешение [5], изменяющийся импеданс контакта электрода с кожей, ограниченное количество независимых измерений и низкое соотношение сигнал / шум [6], что является причиной неточного моделирования системы [7].

В последние годы появилось много автоматических систем для классификации риска РМЖ. Категоризация РМЖ – это проблема классификации, которая требует выделения пространства информативных признаков – дескрипторов и последующей классификации. Однако один классификатор не может изучить все особенности обнаружения РМЖ (Н. Wang и др., 2018). Учитывая недостаток использования только одного классификатора, предлагаются различные алгоритмы, основанные на ансамбле

¹ Пат. 2504328 Российская Федерация. Устройство для контроля анизотропии электрической проводимости биотканей / Томакова Р. А., Филист С. А., Кузьмин А. А.,

Кузьмина М. Н., Алексенко В. А., Волков И. И. № 2012128471/14; заявл. 06.07.12; опубл. 20.01.14.

классификаторов. М. Ф. Акау использовал гибридный метод, предложенный Чжаном и др., где авторы представили гибридный классификатор с различными наборами признаков и использовали SVM для классификации. Нечеткий подход для выбора признака и метод нечеткого ближайшего соседа для обнаружения РМЖ объединены в гибридную систему классификации для обнаружения РМЖ (А. Onan, 2015).

Совокупность классификаторов является важным методом повышения производительности одного классификатора (L. Rokach, 2010). Предсказания, полученные с помощью одного классификатора, объединяются различными методами в классификаторах, основанных на ансамбле, что улучшает общее предсказание и дает более точные прогнозы, чем с помощью одного классификатора (Т. G. Dietterich, 1997). В типичных настройках классификаторов на основе ансамблей классификаторов обучающие данные реплицируются k раз, а затем создаются k классификаторов путем повторной выборки исходных данных (L. Breiman, 1996). Аналогичным образом существуют различные методы голосования для классификации. Наиболее распространенный подход к голосованию заключается в объединении результатов классификаторов базового уровня с использованием множества. Однако эта стратегия не использует выборку метаданных, и все обучающие наборы и классификаторы используют одну и ту же технику голосования (S. Dzeroski and B. Zenko, 2004) [8].

Несмотря на то, что предыдущие исследования показали, что использование

ансамбля классификаторов улучшает результаты классификации, использование ансамблей классификаторов в системах поддержки принятия решений при диагностике РМЖ биоимпедансными методами в научной литературе освещено недостаточно [9]. Поэтому научнотехнической задачей данной работы является устранение этого пробела путем разработки гибридного классификатора риска РМЖ на основе биоимпедансных исследований [10].

Материалы и методы

За основу метода классификации риска РМЖ принят мультимодальный подход, основанный на методе биоимпедансной спектроскопии [11]. Согласно этому подходу необходимо построить несколько моделей классификаторов, которые основаны на различных методах классификации и на различных методах формирования дескрипторов, с последующей агрегацией их решений [12; 13].

Структурная схема мультимодального классификатора риска РМЖ, включающая три канала анализа данных биоимпедансных исследований, представлена ниже (рис. 1). Для получения сырых данных биоимпедансного анализа в нем используется матрица электродов [14]. Блок формирования дескрипторов является по существу блоком построения параметрической модели биоимпеданса МЖ. После формирования параметрических моделей биоимпеданса их параметры используются в качестве дескрипторов двухуровневого классификатора в первом канале мультимодального классификатора (рис. 1).




Рис. 1. Структурная схема мультимодального классификатора риска рака молочной железы

Fig. 1. Structural diagram of the multimodal breast cancer risk classifier

Этот классификатор может выдавать показатели риска РМЖ как дифференцированно по электродам матрицы, так и интегрально по всей матрице. Так как лицу, принимающему решение (ЛПР), весьма трудно оценить показания во всех отведениях матрицы электродов, то эти показания желательно представить в виде изображения, что осуществляется во втором канале мультимодального классификатора [15].

Кроме двухуровневого классификатора в первый канал мультимодального классификатора введен моночастотный классификатор. В его задачу входит получить отсчеты биоимпеданса в отведениях на фиксированной частоте. Это напараметрический классификатор, в котором в качестве дескрипторов используются отсчеты действительных и мнимых составляющих биоимпеданса ReZ и ImZ на определенных частотах. Полученные изображения анализируются ЛПР субъективно или объективно посредством сверточной нейронной сети (СНС) в третьем канале мультимодального классификатора. Анализируя данные о риске РМЖ с трех каналов, ЛПР может проводить повторные

исследования путем смены дислокации матрицы электродов относительно МЖ, получая тем самым наиболее информативное изображение и наиболее стабильные показания объективного контроля риска РМЖ.

Биоимпедансный преобразователь накладывается на области интереса МЖ. При этом в качестве сигнальных электродов используются электроды матрицы электродов, которые непосредственно контактируют с поверхностью кожи МЖ. Индифферентный электрод может быть прикреплен к любой конечности, как это показано ниже (рис. 2).

Во время измерения между индифферентным электродом и измерительными электродами матрицы электродов на биоимпедансном преобразователе прикладывается переменное напряжение [16]. Ток проходит от руки пациента к высокопроводящей грудной мышце, которую можно рассматривать как изопотенциальную плоскость. Таким образом, между грудной мышцей и зондом, прижатым к груди лежащего пациента, создается примерно параллельная электрическая конфигурация (рис. 3).




Рис. 2. Измерение биоимпеданса молочной железы: а – места крепления электродов на теле женщины; б – схема снятия показаний [14]

Fig. 2. Breast bioimpedance measurement: a – electrode attachment points on the body of a woman; б – the scheme of taking readings [14]




Рис. 3. Эквивалентная электрическая схема взаимодействия электродов и биоматериала молочной железы

Fig. 3. Equivalent electrical circuit of the interaction between electrodes and breast biomaterial

Эквивалентная схема (рис. 3) соответствует импедансу Z_2 , показанному на рисунке 2, б. В соответствии с законами

электротехники выражение для эквивалентного импеданса, приведенного на рисунке 3, имеет вид

$$Z_2 = \frac{R_1}{j\omega C_1 \left(R_1 + \frac{1}{j\omega C_1} \right)} + R_2 + \frac{R_3}{j\omega C_3 \left(R_3 + \frac{1}{j\omega C_3} \right)}. \quad (1)$$

После выделения активной $a(\omega)$ и реактивной $b(\omega)$ составляющих импеданса имеем

$$a(\omega) = \left(R_2 + \frac{R_1}{1 + \omega^2 R_1^2 C_1^2} + \frac{R_3}{1 + \omega^2 R_3^2 C_3^2} \right), \quad (2)$$

$$b(\omega) = -\omega \left(\frac{R_1^2 C_1}{1 + \omega^2 R_1^2 C_1^2} + \frac{R_3^2 C_3}{1 + \omega^2 R_3^2 C_3^2} \right). \quad (3)$$

Выбирается линейка исследуемых частот M . На каждой из M выбранных частот определяется импеданс биоматериала. На каждой частоте выполняется 10 измерений биоимпеданса с последующим усреднением. Действительные и мнимые части биоимпеданса определяются по методике, приведенной в [4].

После получения $a(\omega)$ и $b(\omega)$ для всех электродов матрицы электродов (рис. 2, а) приступаем к определению параметров модели Z_2 для каждого из этих электродов. Алгоритм для определения параметров моделей (рис. 3) рассмотрен в [17] и заключается в решении систем нелинейных алгебраических уравнений.

Практика решения таких уравнений показала, что при отсутствии дополнительной информации о параметрах модели имеем множество решений, из которых необходимо выбрать оптимальное. При этом вызывают определенные трудности в распределении импеданса по RC -двухполюсникам, представляющим биоимпедансную модель МЖ [17]. Так как матричный электрод и индифферентный электрод имеют разную конструкцию, то очевидно, что в модели импеданса (2) и (3) параметры модели C_1R_1 и C_3R_3 существенно отличаются. В этом случае целесообразно сначала определить параметры первого двухполюсника,

соответствующего матричному электроду, а затем параметры второго двухполюсника, соответствующего индифферентному электроду.

Для понимания такого подхода рассмотрим рисунок 2, б. Между парой матричных электродов включаем эквивалентное сопротивление Z_1 . Его также, как и Z_2 , можно представить в виде двух последовательно соединенных двухполюсников. Но, в отличие от Z_2 , параметры этих двухполюсников можно принять идентичными, так как они расположены на малом расстоянии друг от друга. При этом активным сопротивлением R_2 в уравнении (2) можем пренебречь по той же причине.

На рисунке 4 представлена схема определения сопротивлений Z_1 и Z_2 согласно рисунку 2, б. Вначале ключ SA находится в положении 1 и измеряется биоимпеданс Z_1 между парой матричных электродов. Для определения параметров модели Z_1 уравнения (4) и (5) запишутся следующим образом:

$$a(\omega) = \left(\frac{2R_1}{1 + \omega^2 R_1^2 C_1^2} \right), \quad (4)$$

$$b(\omega) = -\omega \left(\frac{2R_1^2 C_1}{1 + \omega^2 R_1^2 C_1^2} \right). \quad (5)$$




Рис. 4. Схема измерения импедансов Z_1 и Z_2

Fig. 4. Diagram of measuring impedances Z_1 and Z_2

Анализируя уравнения (4) и (5), приходим к выводу, что для построения параметрической модели Z_1 необходимо определить только C_1 , которое может быть определено из квадратных алгебраических уравнений, полученных из уравнений (4) и (5). Однако эти решения нуждаются в оптимизации, так как каждая частота анализа в общем случае даст свое значение емкости C_1 . Для

оптимизации ее значений существуют множество методов, в т. ч. и статистических. В данной работе для оптимизации значений C_1 используем многослойную нейронную сеть прямого распространения сигнала [18; 19; 20]. Схема алгоритма определения параметров емкости C_1 посредством искусственной нейронной сети (ИНС) представлена ниже (рис. 5).




Рис. 5. Схема алгоритма определения параметров емкости C_1 посредством искусственной нейронной сети

Fig. 5. Diagram of the algorithm for determining the capacitance parameters C_1 using an artificial neural network

В блоке 1 определяется динамический диапазон резистора R_1 . Технология его определения изложена в работе [5]. В блоке 2 определяется частотный диапазон тока зондирования. Здесь надо выбрать не только границы частотного диапазона, но и контрольные точки на частотной оси, на которых определяется импеданс модели.

К сожалению, в научно-технической литературе мало место уделено этому вопросу. Здесь обычно исходят из наличия технических средств, которые позволяют построить измерительный комплекс в выбранном диапазоне частот.

В блоке 3 определяется динамический диапазон C_1 . Его можно вычислить путем решения алгебраических квадратных уравнений (4), (5) относительно C_1 . Например, из (4) на i -й частоте имеем

$$C_1 = -\frac{1}{\omega_i^2 R_1^2} + \sqrt{\frac{2}{a(\omega_i) \omega_i^2 R_1}}. \quad (6)$$

В блоке 4 формируются RC -двухполюсники со случайными параметрами, выбранными из установленных динамических диапазонов независимых переменных, определяются их параметры $a(\omega_i)$, $b(\omega_i)$, которые в данном случае также являются независимыми переменными, и строятся таблицы объектов-признак, в которых в качестве цели выступает значение емкости C_1 .

В блоке 5 осуществляется формирование структуры ИНС прямого распространения сигнала (рис. 6). В блоке 6 осуществляется обучение нейронной сети. Для обучения ИНС используется алгоритм обучения с учителем.




Рис. 6. Структура искусственной нейронной сети прямого распространения сигнала для построения модели пассивного RC -двухполюсника для импеданса Z_1

Fig. 6. Structure of the artificial neural network for direct signal propagation to build a passive RC two-pole model for impedance Z_1

Для управляемого обучения пользователю требуется самостоятельно подготовить набор требуемых обучающих данных (блок 4). Они являются входными данными и соответствующим им

выходом (значение C_1). Сама сеть устанавливает связь между первыми и вторыми. Затем ИНС обучается с помощью алгоритма управляемого обучения, при котором используются данные для

корректировки весов сети и ее пороговые значения для того, чтобы максимально уменьшить ошибку прогноза на обучающем множестве.

В блоке 7 осуществляется проверка качества модели. Если показатели качества неудовлетворительные, то осуществляется переход на блок 4 с последующим дополнением образцов в обучающей выборке и модификацией структуры ИНС. Если показатели качества удовлетворительны, то осуществляется переход ИНС в рабочий режим с загрузкой неизвестных образцов и определение Цели (блоки 8, 9, 10). После обучения ИНС используем ее для прогнозирования ситуации, когда выходные значения неизвестны.

Для построения модели Z_2 ключ SA (рис. 4) устанавливается в положение 2. В этом случае напряжение подается на биоматериал с импедансом Z_2 , эквивалентное сопротивление которого соответствует уравнениям (2) и (3). Учитывая, что параметры первого двухполюсника были определены в процессе

эксперимента с ключом SA в положении 1, то необходимо только определить параметры модели R_2 , R_3 , C_3 .

Однако, если рассмотреть эквивалентную схему (рис. 3), видим, что здесь так же, как и при определении параметров эквивалентной схемы импеданса Z_2 , можно экспериментально определить сопротивление двухполюсника на постоянном токе. Это сопротивление, согласно эквивалентной схеме, равно $R_{\text{общ}} = R_1 + R_2 + R_3$. Если $R_{\text{общ}}$ определяется экспериментально, то в качестве априорной информации используем значение $R^* = R_{\text{общ}} - R_1$.

Параметры C_3 и R_3 определяем по способу, аналогичному определению параметра C_1 . Таким образом, используем алгоритм, аналогичный алгоритму, схема которого представлена на рисунке 5, и ИНС прямого распространения сигнала. В отличие от ИНС (рис. 6) у ИНС для определения параметров двухполюсника Z_2 будет два выхода, а вектор Цель будет двухкомпонентный. Структура этой ИНС показана ниже (рис. 7).




Рис. 7. Структура искусственной нейронной сети прямого распространения сигнала для построения модели пассивного RC-двухполюсника для импеданса Z_2

Fig. 7. Structure of the artificial neural network for direct signal propagation to build a passive RC two-pole model for impedance Z_2

Получив соответствующие параметры модели импеданса, можем построить структуру ИНС, предназначенную для классификации риска РМЖ, пример которой представлен на рисунке 8. В данную структуру входят ИНС NET1 и NET2. NET1 определяет риски РМЖ по импедансу Z_2 для каждого электрода электродной матрицы. Обычно используется матрица 16×16

электродов, поэтому структура ИНС представлена для 256 электродов. После определения параметров эквивалентных двухполюсников для всех электродов матрицы, они последовательно через мультиплексор подаются на входы NET1, которая принимает решение по риску РМЖ на основе данных, поступающих с одного электрода матрицы.




Рис. 8. Структура искусственной нейронной для оценки риска рака молочной железы на основе данных биоимпедансных исследований

Fig. 8. Structure of the artificial neural network for assessing the risk of breast cancer based on bioimpedance research data

NET2 обобщает показатели риска РМЖ по всем электродам матрицы ИНС. На ее входы из запоминающего устройства (ЗУ) поступают риски РМЖ, вычисленные ИНС NET1 по всем электродам матрицы, а на ее выходе имеем интегральный риск РМЖ. Координацию работы блоков и синхронизацию данных в такой ИНС осуществляет блок управления (БУ).

Результаты и их обсуждение

Для проведения биоимпедансных исследований использовалось устройство сбора данных (УСД), выполненное по аналогам, описанным в [4; 5]. На рисунке 9 показана структурная схема УСД при моделировании эквивалентного двухполюсника с импедансом Z_2 . Для согласования УСД с биообъектом (БО) использовалось устройство связи с

объектом (УСО), содержащее усилители, включенные на выходе цифроаналогового преобразователя (ЦАП) и на входе аналого-цифрового преобразователя (АЦП) УСД.

УСО позволяет осуществлять связь с БО посредством управления подключением электродов отведений к

генератору, функции которого как у ЦАП. Частотный диапазон зондирующего тока составлял от нуля герц до 20 кГц. Величина зондирующего тока подбиралась индивидуально для каждого пациента и лежала в диапазоне от 10 до 20 мкА. Рассмотрим пример его реализации (рис. 10).




Рис. 9. Структурная схема устройства сбора данных при моделировании эквивалентного двухполюсника с импедансом Z_2

Fig. 9. Structural diagram of the data collection device when modeling the equivalent two-pole with impedance Z_2




Рис. 10. Схема электрическая принципиальная устройства связи с биообъектом

Fig. 10. Schematic electrical diagram of the device for communication with the bio-object

В зависимости от того, какая модель эквивалентного двухполюсника создается, УСД выполняется в двух исполнениях. На схеме УСД (рис. 9) на каждый электрод матрицы электродов подается зондирующий ток с ЦАП. Конкретно, какой из 256 электродов подключен к ЦАП, определяет демультиплексор. При этом индифферентный электрод подключен к БО постоянно, независимо от того, какой из электродов матрицы электродов выбран демультиплексором.

На рисунке 11 показана структурная схема УСД при моделировании эквивалентного двухполюсника с импедансом Z_1 . Здесь используются два

мультиплексора (мультиплексор и демультиплексор). Демультиплексор выбирает первый электрод отведения, а мультиплексором выбирается второй электрод отведения. К выходам демультиплексора подключены все 256 электродов матрицы электродов, а ко входам мультиплексора подключены 255 электродов матрицы, первый электрод не подключается, так как отведение образуется парой разных электродов. Если к мультиплексору в качестве 256 электрода подключить индифферентный электрод, то схемы (рис. 9 и 11) объединяются в одну универсальную.




Рис. 11. Структурная схема устройства сбора данных при моделировании эквивалентного двухполюсника с импедансом Z_1

Fig. 11. Structural diagram of the data collection device when modeling the equivalent two-pole with impedance Z_1

Рассмотрим функциональную схему устройства для спектроскопии биоимпеданса посредством матрицы электродов (УСБПМЭ) (рис. 12).

Устройство содержит микроконтроллер 1 и ЦАП 2, посредством которого формируются импульсы зондирующего тока различной частоты, которые обеспечивают возможность формирования импедансных диаграмм в отведениях. Для согласования выхода ЦАП 2 с БО 7

используется фильтр нижних частот (ФНЧ) 3 и усилитель 4. Резистор 9 и усилитель 10 выполняют функцию преобразователя ток-напряжение, который позволяет микроконтроллеру 1 контролировать ток через БО 7. ЦАП 2 управляет током в БО. Двухканальный АЦП 11 обеспечивает работу синхронного детектора. Для формирования отведений используются мультиплексор 5 и демультиплексор 8.




Рис. 12. Функциональная схема устройства для спектроскопии биоимпеданса посредством матрицы электродов

Fig. 12. Functional diagram of the device for bioimpedance spectroscopy using an electrode array

Программное обеспечение (ПО) для УСБПМЭ включает ряд интерфейсных окон, предназначенных для его настройки. В качестве входных параметров ПО позволяет пользователю задать амплитуду, частоту и частотный

диапазон инжектируемого тока, частоту дискретизации ЦАП и АЦП.

При получении импедансных диаграмм необходимо задать параметры исследования, которые задаются в интерфейсном окне (рис. 13).




Рис. 13. Интерфейсное окно для задания параметров биоимпедансного исследования

Fig. 13. Interface window for setting parameters of the bioimpedance study

Параметрами режима являются:

- динамический диапазон напряжения ($U_{\max} \dots U_{\min}$) – задается в диапазоне от -15 В до $+15$ В, которое подается на биообъект;

- форма зондирующего тока: импульсы, пилообразная, синусоидальная, постоянный ток;

- шаг дискретизации сигнала по времени для АЦП (Δ), которое задается в диапазоне $0,015$ кГц – 10 МГц;

- длительность кадра « T », в котором формируются данные для передачи в компьютер.

Для управления генератором синусоидального напряжения, выполненным на блоках 2, 3 и 4, в памяти компьютера 13 создается массив, который перегружается через Bluetooth 12 в буфер ЦАП, который имеет установленный размер 128×32 байт. Дискретные отсчеты ЦАП_{*i*} генерации синусоидального напряжения вычисляются по формуле

$$\text{ЦАП}_i = U \cdot \sin(2 \cdot \pi \cdot f \cdot i), \quad (7)$$

где i – номер отсчета в регистре ЦАП; U – амплитуда синусоидального напряжения на выходе генератора.

АЦП загружает дискретные данные в буфер размером 256×32 байт. Преобразование их в вольты осуществляется по формуле

$$U = Y \cdot D / 8192, \quad (8)$$

где U – напряжение на входе АЦП (в вольтах); Y – код на выходе АЦП; D – динамический диапазон на входе АЦП (± 5 В), $(-8192 \dots 8191)$ – формат знакового целого двухбайтового числа, в котором хранятся данные в буфере.

Файл данных сохраняется в компьютере с расширением “.data” [21; 22].

Для настройки ИНС со структурой, (рис. 6–8) использовалось ПО Neurowork, разработанное в среде Matlab на кафедре биомедицинской инженерии ЮЗГУ. ПО Neurowork предоставляет пользователю ряд возможностей для построения систем искусственного интеллекта. Эти возможности представлены в виде вкладок GuiData и GuiNet, примеры работы с которыми описаны в [23].

Экспериментальное исследование мультимодального классификатора проводилось на физической модели с использованием включений большей проводимости (имитация опухоли) различных типов и размеров, а также при различных положениях включений. Физическая модель представляет собой емкость, наполненную физиологическим раствором (удельное сопротивление $\rho = 0,710$ Ом·м), в который последовательно на определенную глубину опускают предметы с большей или меньшей электропроводностью, создавая тем самым зоны неоднородной проводимости.

На рисунке 14, а показан пример биоимпедансного изображения, в котором четко видны два объекта возмущения проводимости, создаваемые проводящим и непроводящим включениями. Разница проводимостей по отношению к фону приблизительно на $+0,9$ и на $-0,9$. На рисунке 14, б показан пример биоимпедансного изображения с возмущающим объектом, погруженным на $0,5$ мм в раствор с проводимостью на $+0,1$ выше по отношению к фоновой.




Рис.14. Биоимпедансные изображения, полученные на фантоме: а – два возмущающих объекта с изменениями проводимостей на $+0,9$ и $-0,9$ по отношению к фоновой; б – один возмущающий объект с изменением проводимости на $+0,1$ по отношению к фоновой

Fig. 14. Bioimpedance images obtained on a phantom: а – two disturbing objects with conductivity changes of $+0,9$ and $-0,9$ relative to the background; б – one disturbing object with a conductivity change of $+0,1$ relative to the background

Всего в обучающую выборку было включено 100 изображений с различными включениями с вариацией проводимости в диапазоне от 1,9 до 1,1 от фоновой. На основе полученных изображений в двухуровневой нейронной сети первого канала определялся интегральный риск РМЖ по всем пикселям изображения. ROC-анализ представленной системы машинного обучения показал, что диагностическая чувствительность и диагностическая специфичность на всех тестовых выборках превышает величину 0,74. Этого достаточно для использования представленной модели мультимодального классификатора для скринингового метода [24]. Таким образом, мультимодальный классификатор в первом канале позволяет обнаруживать изменения проводимости в солевой среде, что делает его жизнеспособной альтернативой для проведения маммографических исследований посредством

рентгеновских и ультразвуковых исследований [25].

Предлагаемая модель мультимодального классификатора имеет преимущества по сравнению с другими известными устройствами биоимпедансной спектроскопии, поскольку концентрирует функции: генерации электрического тока, измерения напряжения, мультиплексирования и демодуляции электродов, сокращая количество модулей системы и ее соответствующих интерфейсов, что облегчает ее реализацию при низких затратах.

Выводы

Таким образом, мультимодальный классификатор позволяет определить риск онкологического заболевания по результатам спектроскопии биоимпеданса в области дислокации матрицы электродов. Также посредством мультимодального классификатора имеем возможность контролировать реакции

организма на лечебно-оздоровительные процедуры, следовательно, осуществлять управление планом лечения. Создана принципиально новая модель интеллектуальной поддержки принятия врачебных решений, интегрирующая возможности спектроскопии биоимпеданса, СНС и экспертного оценивания. Следует отметить, что современные данные, подтверждающие возможность разделения доброкачественных и злокачественных

опухолей МЖ с помощью методов биоимпедансометрии, весьма ограничены. Необходимы дальнейшие исследования этого вопроса, чтобы в полной мере использовать методы, основанные на биоимпедансном анализе, для выявления рака МЖ, особенно для дифференциальной диагностики рака МЖ. Если это удастся, можно ожидать сокращения числа доброкачественных биопсий.

Список литературы

1. Алиева Г. С., Корженкова Г. П., Колядина И. В. Анализ ключевых рентгенологических характеристик раннего инвазивного рака молочной железы стадий T_{1a}-bN₀M₀ и DCIS // Онкологический журнал: лучевая диагностика, лучевая терапия. 2021. Т. 4, № 1. С. 9–19. <https://doi.org/10.37174/2587-7593-2021-4-1-9-19>
2. Объективизация топографо-анатомических показателей злокачественной опухоли молочной железы при ультразвуковом исследовании / А. Р. Хамитов, А. Х. Исмагилов, Н. А. Савельева, И. А. Киясов // Поволжский онкологический вестник. 2017. Т. 1, № 28. С. 59–64.
3. Zou Y., Guo Z. A review of electrical impedance techniques for breast cancer detection // Medical Engineering & Physics. 2003. Vol. 25, N 2. P. 79–90. [https://doi.org/10.1016/s1350-4533\(02\)00194-7](https://doi.org/10.1016/s1350-4533(02)00194-7)
4. Шаталова О. В. Интеллектуальные системы мониторинга медицинских рисков с учетом биоимпедансных исследований: монография / Юго-Западный государственный университет. Курск, 2020. 356 с.
5. Технологии биоимпедансной спектроскопии в системах поддержки принятия решений при диагностике социально значимых заболеваний / О. В. Шаталова, Н. С. Стадниченко, М. А. Ефремов, И. А. Башмакова, А. В. Лях, А. В. Серебровский // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 4. С. 148–174. <https://doi.org/10.21869/2223-1536-2023-13-4-148-174>
6. Биомедицинская спектроскопия в классификаторах функционального состояния органов и систем человека, построенных на основе гибридных технологий искусственного интеллекта / О. В. Шаталова, А. В. Серебровский, Н. С. Стадниченко, А. Ю. Новоселов, А. В. Лях // Системный анализ и управление в биомедицинских системах. 2023. Т. 22, № 2. С. 100–113. <https://doi.org/10.36622/VSTU.2023.22.2.015>

7. Модели импеданса биоматериала для формирования дескрипторов в интеллектуальных системах диагностики инфекционных заболеваний / А. В. Мирошников, Н. С. Стадниченко, О. В. Шаталова, С. А. Филист // Моделирование, оптимизация и информационные технологии. 2020. Т. 8, № 4. С. 1–14. <https://doi.org/10.26102/2310-6018/2020.31.4.018>
8. An Automatic Detection of Breast Cancer Diagnosis and Prognosis Based on Machine Learning Using Ensemble of Classifiers / U. Naseem, J. Rashid, L. Ali, J. Kim, Q. E. Ul Haq, M. J. Awan, M. Imran // IEEE Access. 2022. Vol. 10. P. 78242–78252.
9. Филист С. А., Емельянов С. Г., Рыбочкин А. Ф. Нейросетевой решающий модуль для исследования живых систем // Известия Курского государственного технического университета. 2008. № 2 (23). С. 77–82.
10. A method for creating fuzzy neural-network models using the MATLAB package for biomedical applications / V. V. Zhilin, S. A. Filist, Kh. A. Rakhim, O. V. Shatalova // Biomedical Engineering. 2008. N 42 (2). P. 64–66. <https://doi.org/10.1007/s10527-008-9019-y>
11. Филист С. А., Кассим К. Д. А., Руцкой Р. В. Гибридные решающие системы для прогнозирования послеоперационных осложнений у больных с доброкачественной гиперплазией предстательной железы // Известия Юго-Западного государственного университета. 2013. № 5 (50). С. 40–49.
12. Гибридные интеллектуальные модели для сегментации изображений рентгенограмм грудной клетки / С. А. Филист, Р. А. Томакова, С. В. Дегтярев, А. Ф. Рыбочкин // Медицинская техника. 2017. № 5 (305). С. 41–45.
13. Филист С. А., Томакова Р. А., Насер А. А. Нечеткие нейросетевые технологии для выделения сегментов с патологическими образованиями и морфологическими структурами на медицинских изображениях // Биомедицинская радиоэлектроника. 2012. № 4. С. 43–50.
14. Мультимодальный классификатор риска рака молочной железы на основе анализа импеданса биоматериала / А. В. Серебровский, О. В. Шаталова, А. В. Лях, И. А. Халин, И. А. Башмакова, З. У. Протасова // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. № 14 (2). С. 142–159. <https://doi.org/10.21869/2223-1536-2024-14-2-142-159>
15. Классификации биологических объектов на основе многомерного биоимпедансного анализа / А. В. Мирошников, О. В. Шаталова, Н. С. Стадниченко, Л. В. Шульга // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 3/4. С. 29–49.

16. Филист С. А., Шаталова О. В., Богданов А. С. Модели биоимпеданса при нелинейной вольтамперной характеристике и обратимом пробое диэлектрической составляющей биоматериала // Бюллетень сибирской медицины. 2014. Т. 13, № 4. С. 129–135.

17. Алгоритм оптимизации модели Войта в классификаторах функционального состояния живых систем / А. В. Мирошников, О. В. Шаталова, М. А. Ефремов, Н. С. Стадниченко, А. Ю. Новоселов, А. В. Павленко // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2022. Т. 12, № 2. С. 59–75. <https://doi.org/10.21869/2223-1536-2022-12-2-59-75>

18. Использование гибридных нейросетевых моделей для многоагентных систем классификации в гетерогенном пространстве информативных признаков / А. Г. Курочкин, В. В. Жилин, С. А. Суржикова, С. А. Филист // Прикаспийский журнал: управление и высокие технологии. 2015. № 3(31). С. 85–95.

19. Курочкин А. Г., Протасова В. В., Филист С. А., Шуткин А. Н. Нейросетевые модели для метаанализа медико-экологических данных // Нейрокомпьютеры. Разработка, применение. 2015. № 6. С. 42–48.

20. Филист С. А., Шаталова О. В., Ефремов М. А. Гибридная нейронная сеть с макрослоями для медицинских приложений // Нейрокомпьютеры. Разработка и применение. 2014. № 6. С. 35–39.

21. Суржикова С. Е., Шаталова О. В., Федянин В. В. Программно-аппаратный комплекс диагностики социально значимых заболеваний // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2015. № 2 (15). С. 79–87.

22. Суржикова С. Е., Шаталова О. В., Федянин В. В. Программно-аппаратный комплекс для анализа вольтамперных характеристик биоактивных точек на основе модуля L-CARD E20-10 / С.Е. Суржикова // Прикаспийский журнал: управление и высокие технологии. 2015. № 2 (30). С. 150–161.

23. Мультимодальный классификатор риска кардиореспираторных заболеваний с учетом сопутствующих заболеваний и эффекта синергии / Е. В. Петрунина, О. В. Шаталова, Хайдер А. Х. Алавси, В. В. Песок, А. А. Кузьмин, Л. В. Шульга // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 2. С. 81–105. <https://doi.org/10.21869/2223-1536-2024-14-2-81-105>

24. Распределенные автономные интеллектуальные агенты для мониторинга и метаанализа эффективности управления живыми системами / Т. В. Петрова, А. А. Кузьмин, Д. Ю. Савинов, В. В. Серебровский // Прикаспийский журнал: управление и высокие технологии. 2017. № 40 (4). С. 61–73.

25. Структурно-функциональная модель для мониторинга влияния управляющих воздействий на функциональное состояние самоорганизующихся систем / П. С. Кудрявцев, А. Н. Шуткин, В. В. Протасова, С. А. Филист // Прикаспийский журнал: управление и высокие технологии. 2015. № 2 (30). С. 105–118.

References

1. Alieva G.S., Korzhenkova G.P., Kolyadina I.V. Analysis of key radiological characteristics of early invasive breast cancer stages T1a-bN0M0 and DCIS. *Onkologicheskii zhurnal: luchelevaya diagnostika, luchelevaya terapiya = Oncological Journal: Radiodiagnosis, Radiotherapy*. 2021;4(1):9–19. (In Russ.) <https://doi.org/10.37174/2587-7593-2021-4-1-9-19>
2. Khamitov A.R., Ismagilov A.Kh., Savel'eva N.A., Kiyasov I.A. Objectification of topographic-anatomical indicators of malignant breast tumors in ultrasound examination. *Povolzhskii onkologicheskii vestnik = Volga Oncology Bulletin*. 2017;1(28):59–64. (In Russ.)
3. Zou Y., Guo Z. A review of electrical impedance techniques for breast cancer detection. *Medical Engineering & Physics*. 2003;25(2):79–90. [https://doi.org/10.1016/s1350-4533\(02\)00194-7](https://doi.org/10.1016/s1350-4533(02)00194-7)
4. Shatalova O.V. Intelligent systems for monitoring medical risks considering bioimpedance studies. Kursk: Yugo-Zapadnyi gosudarstvennyi universitet; 2020. 356 p. (In Russ.)
5. Shatalova O.V., Stadnichenko N.S., Efremov M.A., Bashmakova I.A., Lyakh A.V., Serebrovsky A.V. Technologies of bioimpedance spectroscopy in decision support systems for the diagnosis of socially significant diseases. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2023;13(4):148–174. (In Russ.) <https://doi.org/10.21869/2223-1536-2023-13-4-148-174>
6. Shatalova O.V., Serebrovsky A.V., Stadnichenko N.S., Novoselov A.Yu., Lyakh A.V. Biomedical spectroscopy in classifiers of the functional state of human organs and systems based on hybrid artificial intelligence technologies. *Sistemnyi analiz i upravlenie v biomeditsinskikh sistemakh = System Analysis and Control in Biomedical Systems*. 2023;22(2):100–113. (In Russ.) <https://doi.org/10.36622/VSTU.2023.22.2.015>
7. Miroshnikov A.V., Stadnichenko N.S., Shatalova O.V., Filist S.A. Impedance models of biomaterials for forming descriptors in intelligent systems for diagnosing infectious diseases. *Modelirovanie, optimiza-tsiya i informatsionnye tekhnologii = Modeling, Optimization and Information Technologies*. 2020;8(4):1–14. (In Russ.) <https://doi.org/10.26102/2310-6018/2020.31.4.018>
8. Naseem U., Rashid J., Ali L., Kim J., Ul Haq Q.E., Awan M.J., Imran M. An Automatic Detection of Breast Cancer Diagnosis and Prognosis Based on Machine Learning Using Ensemble of Classifiers. *IEEE Access*. 2022;10: 78242–78252.

9. Filist S.A., Emelyanov S.G., Rybochkin A.F. Neural network decision module for studying living systems. *Izvestiya Kurskogo gosudarstvennogo tekhnicheskogo universiteta = Proceedings of the Kursk State Technical University*. 2008;2(23):77–82. (In Russ.)
10. Zhilin V.V., Filist S.A., Rakhim Kh.A., Shatalova O.V. A method for creating fuzzy neural-network models using the MATLAB package for biomedical applications. *Biomedical Engineering*. 2008;42(2):64–66. (In Russ.) <https://doi.org/10.1007/s10527-008-9019-y>
11. Filist S.A., Kassim K.D.A., Rutskiy R.V. Hybrid decision systems for predicting post-operative complications in patients with benign prostatic hyperplasia. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*. 2013;5(50):40–49. (In Russ.)
12. Filist S.A., Tomakova R.A., Degtyarev S.V., Rybochkin A.F. Hybrid intelligent models for segmenting chest X-ray images. *Meditinskaya tekhnika = Medical Technology*. 2017;5(305):41–45. (In Russ.)
13. Filist S.A., Tomakova R.A., Naser A.A. Fuzzy neural network technologies for segmenting pathological formations and morphological structures in medical images. *Biomeditsinskaya radioelektronika = Biomedical Radioelectronics*. 2012;(4):43–50. (In Russ.)
14. Serebrovsky A.V., Shatalova O.V., Lyakh A.V., Khalin I.A., Bashmakova I.A., Protasova Z.U. Multimodal classifier for breast cancer risk based on the analysis of biomaterial impedance. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(2):142–159. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-2-142-159>
15. Miroshnikov A.V., Shatalova O.V., Stadnichenko N.S., Shulga L.V. Classifications of biological objects based on multidimensional bioimpedance analysis. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2020;10(3/4):29–49. (In Russ.)
16. Filist S.A., Shatalova O.V., Bogdanov A.S. Bioimpedance models in nonlinear volt-ammeter characteristics and reversible breakdown of the dielectric component of biomaterial. *Byulleten' sibirskoi meditsiny = Bulletin of Siberian Medicine*. 2014;13(4):129–135. (In Russ.)
17. Miroshnikov A.V., Shatalova O.V., Efremov M.A., Stadnichenko N.S., Novoselov A.Yu., Pavlenko A.V. Algorithm for optimizing the Voit model in classifiers of the functional state of living systems. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering,*

Information Science. Medical Instruments Engineering. 2022;12(2):59–75. (In Russ.) [https://doi.org/ 10.21869/2223-1536-2022-12-2-59-75](https://doi.org/10.21869/2223-1536-2022-12-2-59-75)

18. Kurachkin A.G., Zhilin V.V., Surzhikova S.A., Filist S.A. Using hybrid neural network models for multi-agent classification systems in heterogeneous spaces of informative features. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies.* 2015;3(31):85–95. (In Russ.)

19. Kurachkin A.G., Protasova V.V., Filist S.A., Shutkin A.N. Neural network models for meta-analysis of medical and environmental data. *Neirokomp'yutery. Razrabotka, primeneniye = Neurocomputers. Development and Application.* 2015;(6):42–48. (In Russ.)

20. Filist S.A., Shatalova O.V., Efremov M.A. Hybrid neural network with macro layers for medical applications. *Neirokomp'yutery. Razrabotka i primeneniye = Neurocomputers. Development and Application.* 2014;(6):35–39. (In Russ.)

21. Surzhikova S.E., Shatalova O.V., Fedyanin V.V. Software and hardware complex for diagnosing socially significant diseases. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering.* 2015;2(15):79–87. (In Russ.)

22. Surzhikova S.E., Shatalova O.V., Fedyanin V.V. Software and hardware complex for analyzing voltammetric characteristics of bioactive points based on the L-CARD E20-10 module. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies.* 2015;2(30):150–161. (In Russ.)

23. Petrunina E.V., Shatalova O.V., Alavsi Haider A.H., Pesok V.V., Kuzmin A.A., Shulga L.V. Multimodal classifier of cardiorespiratory risk taking into account comorbidities and synergy effect. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering.* 2024;14(2):81–105. (In Russ.) [https://doi.org/ 10.21869/2223-1536-2024-14-2-81-105](https://doi.org/10.21869/2223-1536-2024-14-2-81-105)

24. Petrova T.V., Kuzmin A.A., Savinov D.Yu., Serebrovsky V.V. Distributed autonomous intelligent agents for monitoring and meta-analysis of the effectiveness of managing living systems. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies.* 2017;40(4):61–73. (In Russ.)

25. Kudryavtsev P.S., Shutkin A.N., Protasova V.V., Filist S.A. Structural-functional model for monitoring the influence of control actions on the functional state of self-organizing systems. *Prikaspiiskii zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies.* 2015;(2):105–118. (In Russ.)

Информация об авторах / Information about the Authors

Серебровский Андрей Вадимович, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kstu-bmi@yandex.ru

Andrey V. Serebrovsky, Post-Graduate Student of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: kstu-bmi@yandex.ru

Корсунский Никита Александрович, аспирант, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: cor.nick2013@yandex.ru, ORCID: 0009-0005-4606-5517

Nikita A. Korsunsky, Post-Graduate Student, Southwest State University, Kursk, Russian Federation, e-mail: cor.nick2013@yandex.ru, ORCID: 0009-0005-4606-5517

Лях Антон Викторович, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: kstu-bmi@yandex.ru, ORCID: 0009-0008-6217-2840

Anton V. Lyakh, Post-Graduate Student of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: kstu-bmi@yandex.ru, ORCID: 0009-0008-6217-2840

Мишустин Владимир Николаевич, доктор медицинских наук, доцент, профессор кафедры хирургических болезней, Институт непрерывного образования, Курский государственный медицинский университет Министерства здравоохранения Российской Федерации, г. Курск, Российская Федерация, e-mail: vladimirshf2011@yandex.ru, ORCID: 0000-0002-4104-5681

Vladimir N. Mishustin, Doctor of Sciences (Medical), Associate Professor, Professor of the Department of Surgical Diseases, Institute of Continuous Education, Kursk State Medical University Ministry of Health of the Russian Federation, Kursk, Russian Federation, e-mail: vladimirshf2011@yandex.ru, ORCID: 0000-0002-4104-5681

Шаталова Ольга Владимировна, доктор технических наук, доцент, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: shatolg@mail.ru, Researcher ID: C-3687-2015, ORCID: 0000-0002-0901-9272

Olga V. Shatalova, Doctor of Sciences (Engineering), Associate Professor, Professor of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: shatolg@mail.ru, Researcher ID: C-3687-2015, ORCID: 0000-0002-0901-9272

Шульга Леонид Васильевич, доктор медицинских наук, профессор, профессор кафедры охраны труда и окружающей среды, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: otios@mail.ru

Leonid V. Shulga, Doctor of Sciences (Medical), Professor, Professor of the Department of Occupational Safety and Environment, Southwest State University, Kursk, Russian Federation, e-mail: otios@mail.ru