

Оригинальная статья / Original article

<https://doi.org/10.21869/2223-1536-2024-14-2-81-105>

УДК 004.89

Мультиомодальный классификатор риска кардиореспираторных заболеваний с учетом сопутствующих заболеваний и эффекта синергии

Е. В. Петрунина¹, О. В. Шаталова²✉, Хайдер А. Х. Алавси², В. В. Песок²,
А. А. Кузьмин², Л. В. Шульга¹

¹ Московский политехнический университет
ул. Большая Семёновская, д. 38, г. Москва 107023, Российская Федерация

² Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: shatolg@mail.ru

Резюме

Цель исследования – развитие методов синтеза мультиомодальных классификаторов для оценки риска кардиореспираторных заболеваний с учетом коморбидности.

Методы. Разработан метод синтеза классификатора риска внебольничной пневмонии с учетом коморбидности. Метод отличается вводом дополнительного фактора риска, представленного двухконтурной нелинейной моделью реальных факторов риска, с последующим синтезом слабых классификаторов на ее основе. Метод позволяет построить мультиомодальный классификатор риска внебольничной пневмонии, который учитывает взаимное влияние коморбидных заболеваний на суммарный риск. Для построения слабых классификаторов предложено использовать полносвязанную нейронную сеть Хопфилда, отличающуюся многосвязной структурой и двумя задержками на один такт, управляемыми парафазным генератором (с противофазными выходами), обеспечивающими запись в регистры задержек рисков с выходов нейронной сети Хопфилда со сдвигами на один такт. Для обучения слабых классификаторов с нейронной сетью Хопфилда разработан алгоритм, позволяющий обеспечить заданные показатели точности классификации и заданные показатели устойчивости нейронной сети.

Результаты. В ходе экспериментальных исследований мультиомодального классификатора риска внебольничной пневмонии с четырьмя сегментами факторов риска было установлено, что при использовании всех сегментов факторов риска все используемые показатели качества классификации риска внебольничной пневмонии превышают величину 0,8 по всем группам наблюдения. Показатели качества классификации риска артериальной гипертензии как сопутствующего заболевания превышают показатели качества шкалы SCORE в одних и тех же контрольных группах в среднем на 11%.

Заключение. Использование метода синтеза слабого классификатора медицинского риска с учетом коморбидности в мультиомодальном классификаторе риска кардиореспираторных заболеваний открывает новые возможности для доступной и объективной диагностики заболеваний системы дыхания и сердечно-сосудистых заболеваний, расширяя возможности интеллектуальных систем поддержки принятия клинических решений как при терапии, так и при реабилитации.

Ключевые слова: внебольничная пневмония; артериальная гипертензия; коморбидность; мультиомодальный классификатор; нейронная сеть; алгоритм; модель виртуального фактора риска.

© Петрунина Е. В., Шаталова О. В., Алавси Хайдер А. Х., Песок В. В., Кузьмин А. А., Шульга Л. В., 2024

Proceedings of the Southwest State University. Series: Control, Computer Engineering,
Information Science. Medical Instruments Engineering. 2024; 14(2): 81–105

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

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

Для цитирования: 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>

Поступила в редакцию 10.04.2024

Подписана в печать 06.05.2024

Опубликована 28.06.2024

Multimodal risk classifier for cardiorespiratory diseases taking into account concomitant diseases and synergy effect

Elena V. Petrunina¹, Olga V. Shatalova^{2✉}, Hayder A. H. Alawsi², Valeriya V. Pesok², Alexander A. Kuzmin², Leonid V. Shulga²

¹ Moscow Polytechnic University

38 Bol'shaya Semenovskaya Str., Moscow 107023, Russian Federation

² Southwest State University

50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: shatolg@mail.ru

Abstract

The purpose of the research is to develop a methodology for classifying complexly structured halftone images based on a multimodal approach using methods of morphological analysis, spectral analysis and neural network modeling.

Methods. A method for classifying the contours of the boundaries of segments of a complexly structured image is described. The method is based on the fact that in chronic diseases of the pancreas, there is a violation of the integrity of the contour of its border and its waviness increases due to retractions and bulges caused by an alternative inflammatory process. The method includes the stages of normalization of ultrasound images and image segmentation with the selection of the contour of the object of interest. To classify the contour of a segment boundary, it is proposed to use Fourier analysis and neural network technologies. The method is illustrated using the example of classifying the contour of the border of the pancreas on its transcutaneous acoustic image.

Results. Experimental studies of the proposed methods and means for classifying medical risk were carried out on diagnostic tasks according to the following classes: "chronic pancreatitis" – "without pathology". For experimental studies, video sequences of ultrasound images of the pancreas provided by an endoscopist were used. The purpose of the experimental studies was to analyze the classification quality indicators of image classifiers with class segments "Chronic pancreatitis" and "Without pathology". The training sample of video images (frames of video sequences) included 200 examples, one hundred from each class. The quality indicator "Sensitivity" of classification for two classes is 85,7%, the indicator "Specificity" is 87,1%.

Conclusion. The use of the contour analysis method in classifiers of ultrasound images of the pancreas opens up new opportunities for accessible and objective diagnosis of pancreatic diseases, expanding the capabilities of intelligent clinical decision support systems.

Keywords: community-acquired pneumonia; hypertension; comorbidity; multimodal classifier; neural network; algorithm; a virtual risk factor model.

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

Funding: The research was carried out within the framework of the development program of the Federal State Budgetary Educational Institution of Higher Education "Southwestern State University" of the strategic academic leadership program "Priority – 2030".

For citation: Petrunina E.V., Shatalova O.V., Alawsi Hayder A.H., Pesok V.V., Kuzmin A.A., Shulga L.V. Multimodal risk classifier for cardiorespiratory diseases taking into account concomitant diseases and synergy effect. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoje 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>

Received 10.04.2024

Accepted 06.05.2024

Published 28.06.2024

Введение

В современной медицине под коморбидностью понимают сосуществование у пациента двух или более заболеваний вне зависимости от активности каждого из них, взаимосвязанных между собой или совпадающих по времени у одного пациента [1]. В настоящее время исследователей стала привлекать роль хронических сердечно-сосудистых заболеваний (ССЗ) на риск неблагоприятного исхода внебольничной пневмонии (ВП). В ряде исследований показано, что имеющаяся хроническая сердечно-сосудистая патология у умерших пациентов с ВП

встречается в 3 раза чаще, чем у умерших пациентов, не имеющих сердечно-сосудистой патологии [2]. Проведенные исследования указывают на существенную роль артериальной гипертензии (АГ) на увеличение длительности легочной инфильтрации, на развитие осложнений и на прогноз исхода ВП. В [3] показано, что кумулятивный риск АГ значительно увеличивает риск неблагоприятного исхода заболевания системы дыхания (СД) и наоборот. На рисунке 1 показаны кривые кумулятивного риска (КР) наступления конечной точки (КТ) у пациентов с АГ в зависимости от наличия патологии СД.

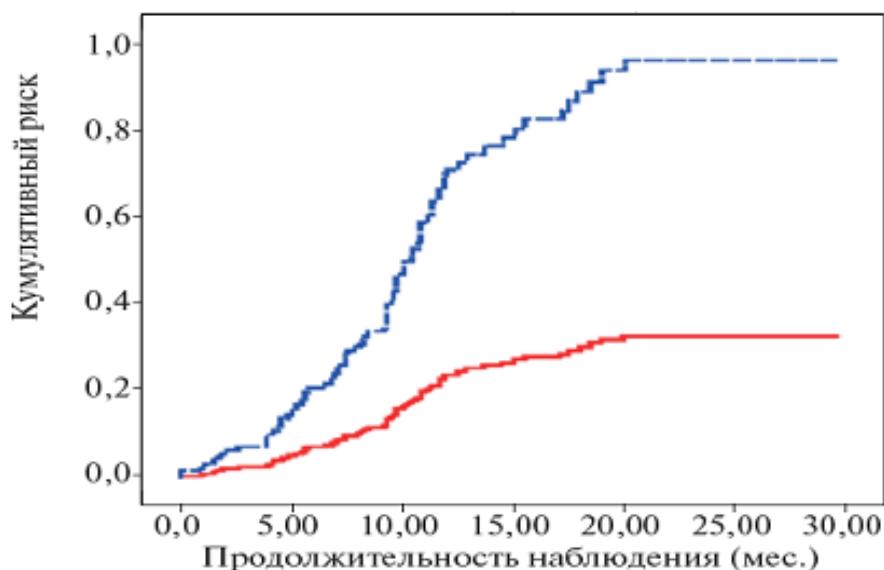


Рис. 1. Кривые кумулятивного риска наступления конечной точки у пациентов с артериальной гипертензией в зависимости от наличия хронических заболеваний системы дыхания: — АГ; - - - АГ+ ВП

Fig. 1. Curves of the cumulative risk of the end point in patients with arterial hypertension depending on the presence of chronic diseases of the respiratory system:
— arterial hypertension; - - - arterial hypertension + community-acquired pneumonia

Известно, что факторы риска (ФР) кардиореспираторных заболеваний часто коррелируют друг с другом, а в некоторых случаях непосредственно влияют друг на друга, что приводит либо к усилению, либо к ослаблению частного риска по данному ФР [4; 5; 6; 7; 8; 9]. Эффект этого влияния может выражаться как в увеличении доли КР, связанного с этим ФР, так и ослаблении сочетанного ФР на риск ССЗ. Этот эффект может наблюдаться как на «сырых» данных, т. е. на результатах классификации медицинского риска (МР) агентами нижнего иерархического уровня, так и на более высоких иерархических структурах.

Материалы и методы

Для оценки влияния риска одного заболевания на риск другого заболевания используют два подхода, оба из которых должны учитывать тот факт, что коморбидные заболевания не только усиливают взаимные МР, но и имеют ряд одинаковых ФР. Поэтому первый подход основан на том, что наличие коморбидности приводит к усилению или снижению влияния ФР на МР коморбидного заболевания. Такой подход позволяет учитывать синергетический эффект на входе классификатора МР [10]. Второй подход учета влияния коморбидности на МР предусматривает учет синергии на основе учета выходов слабых классификаторов (weak classifiers) МР.

Рассмотрим подробнее первый подход. Формально синергетический эффект может быть учтен вводом M

дополнительных (виртуальных) ФР в виде некоторых функций (моделей) от реальных ФР: $f_1(X_1, X_2, \dots, X_N), f_2(X_1, X_2, \dots, X_N), \dots, f_m(X_1, X_2, \dots, X_N), \dots, f_M(X_1, X_2, \dots, X_N)$. Здесь X_1, X_2, \dots, X_N – множество реальных факторов риска количеством N . В качестве моделей виртуальных ФР используем частные функции влияния Z_{ij} и Z_{ji} i -го ФР на j -й ФР и наоборот, определяемые по следующим формулам:

$$\begin{aligned} Z_{ij} &= a_{ii}X_i + a_{ij}X_j + b_{ij}X_iX_j, \\ Z_{ji} &= a_{ji}X_i + a_{jj}X_j + b_{ji}X_iX_j. \end{aligned} \quad (1)$$

При использовании формул (1) целесообразно осуществить масштабирование ФР таким образом, чтобы они находились в одном динамическом диапазоне, например, по формуле

$$\hat{X}_i = \frac{X_i - \min(X_i)}{\max(X_i) - \min(X_i)}. \quad (2)$$

Уравнения (1) позволяют получить виртуальные ФР (ВФР) – Z_{ij} и Z_{ji} . Используя (1), можем построить соответствующие слабые классификаторы, которые назовем классификаторами синергетических каналов (СК). При этом в качестве операндов в левой части уравнений (1) могут рассматриваться ФР, полученные на любом иерархическом уровне мультимодального классификатора риска (ММК). При этом Z_{ij} и Z_{ji} – это разные ВФР, т. е.

$$Z_{ij} \neq Z_{ji}. \quad (3)$$

При учете коморбидности обычно рассматриваются только два сочетанных заболевания, поэтому на входах

синергетических каналов присутствуют либо два скаляра, либо два вектора, определяющие дополнительный риск в результате синергии. Коэффициенты в (1) определяются в процессе построения моделей СК, которые строятся либо на парадигме обучаемых классификаторов, либо на основе алгоритмов математического моделирования мультипараметрических данных, например, методе группового учета аргументов (МГУА) [5; 7; 8]. Формальная модель влияния ФР друг на друга на примере двух ФР: x_1 и x_2 , представлена на рисунке 2. В этой модели ФР модифицируют друг друга посредством ввода двух функций влияния $f_1(x_1, x_2)$ и $f_2(x_1, x_2)$ [11]. Определив согласно (1) новые информативные признаки,

вычисляем частные

коэффициенты уверенности $KY_{1\omega\ell}$ и $KY_{2\omega\ell}$ в риске заболевания класса ω_ℓ . В результате их агрегирования получаем частный риск $KY_{\omega\ell}$ по ФР x_1 и x_2 .

При реализации такого подхода возникает ряд трудностей, связанных с взаимодействием функций влияния и частных коэффициентов уверенности: это взаимодействие может приводить к изменению величины ФР или к модификации слабого классификатора, связанного с этим ФР. Учитывая, что ФР много, то необходимо модифицировать ФР с учетом всех остальных ФР, поэтому очень сложно определить соответствующие функции влияния, используя парадигмы машинного обучения (МО) [12; 13] или экспертного оценивания [14; 15].

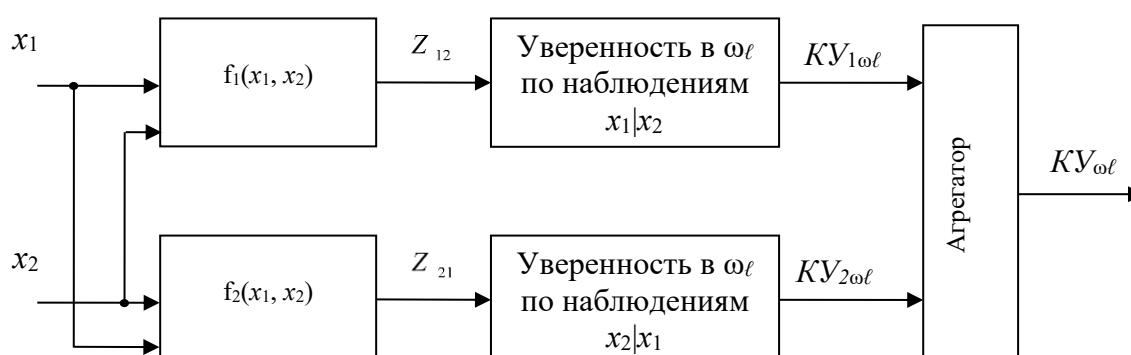


Рис. 2. Схема взаимодействия двух факторов риска в иерархической системе принятия решений

Fig. 2. Scheme of interaction of two risk factors in a hierarchical decision-making system

Как уже было написано выше, второй подход учета влияния коморбидности на МР предусматривает учет синергии на основе учета выходов слабых классификаторов МР. При этом риск коморбидных заболеваний описывается математическими моделями (линейными или нелинейными), например, моделями многомерной линейной регрессии, в

которых МР коморбидных заболеваний $R1$ и $R2$ входят в виде скалярных составляющих:

$$\begin{cases} R1 = [A1] \cdot [X1]^T + [B1] \cdot [X3]^T + c1 \cdot R2, \\ R2 = [A2] \cdot [X2]^T + [B2] \cdot [X3]^T + c2 \cdot R1, \end{cases} \quad (4)$$

где $X1$ и $X2$ – векторы специфических ФР для МР $R1$ и $R2$; $X3$ – вектор общих ФР для МР $R1$ и $R2$; $A1, A2, B1, B2$ –

матрицы коэффициентов многомерной линейной модели рисков коморбидных заболеваний; $c1$ и $c2$ – коэффициенты, учитывающие взаимное влияние МР коморбидных заболеваний.

Учитывая, что в системе уравнений (4) независимыми являются коэффициенты при предикторах риска, т. е. $A1, A2, B1, B2$ и $c1$ и $c2$, система алгебраических уравнений (4) является нелинейной. Для описания методики ее решения запишем (4) в наиболее простом варианте, когда векторы ФР $X1, X2, X3$ являются скалярами:

$$\begin{cases} R1 = a1 \cdot x1 + b1 \cdot x3 + c1 \cdot R2, \\ R2 = a2 \cdot x2 + b2 \cdot x3 + c2 \cdot R1. \end{cases} \quad (5)$$

Осуществив переход в правых частях уравнений (5) к одной зависимой переменной, получим

$$\begin{cases} R1 = \frac{a1}{1 - c1 \cdot c2} \cdot x1 + \frac{a2 \cdot c1}{1 - c1 \cdot c2} \cdot x2 + \frac{b1 + b2 \cdot c1}{1 - c1 \cdot c2} \cdot x3, \\ R2 = \frac{a2}{1 - c1 \cdot c2} \cdot x2 + \frac{a1 \cdot c2}{1 - c1 \cdot c2} \cdot x1 + \frac{b2 + b1 \cdot c2}{1 - c1 \cdot c2} \cdot x3. \end{cases} \quad (6)$$

Таким образом, каждый объект (пациент) имеет две метки – $R1$ и $R2$. В результате построения моделей, соответствующих системам уравнений (4), (5) и (6), необходимо определить коэффициенты при трех ФР, которые удовлетворяли бы априорно выбранным показателям качества этих моделей. Концептуальная модель классификатора представлена ниже (рис. 3).

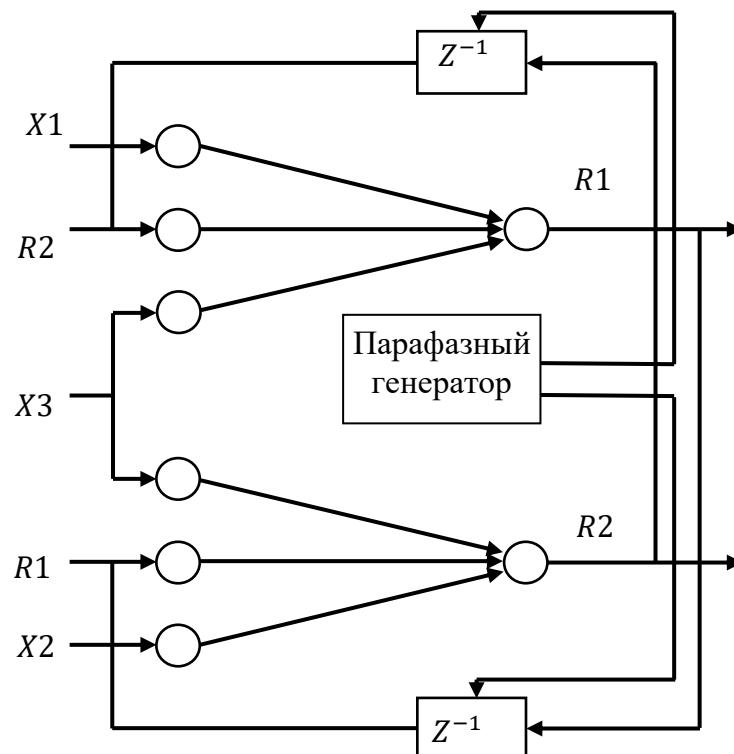


Рис. 3. Концептуальная модель классификатора медицинского риска с учетом синергетического эффекта на основе структуры сети Хопфилда

Fig. 3. Conceptual model of a medical risk classifier taking into account the synergistic effect based on the structure of the Hopfield network

Модель отвечает системе уравнений (5). Характерной особенностью этой модели является наличие задержек на один такт Z^{-1} . Задержки управляются парафазным генератором, на входах которого присутствуют противофазные импульсы, управляющие записью данных с выходов классификатора рисков в регистры задержек. Формально модель рисунка 3 можно рассматривать как одну нейронную сеть (НС) со структурой Хопфилда [16; 17] или как две НС с многосвязной структурой. И в том и в другом случае в структуре НС должна быть предусмотрена задержка на один такт и проведена проверка условия на устойчивость сети.

Под устойчивостью НС здесь понимается процесс обучения сети, в результате выполнения которого приращения переменных на ее выходах по каждому примеру стремятся к нулю. На рисунке 4 показан процесс изменения (динамика) показателей риска $R1$ и $R2$ на выходе синергетических классификаторов от эпохи к эпохе при устойчивой НС:

$$\Delta R1_k = R1_{k+1} - R1_k; \quad \Delta R2_k = R2_{k+1} - R2_k,$$

где $k = 0, 1, \dots, i-1$ – номер эпохи обучения; i – число эпох обучения, определяемое в блоке 6 согласно схеме алгоритма (рис. 5).

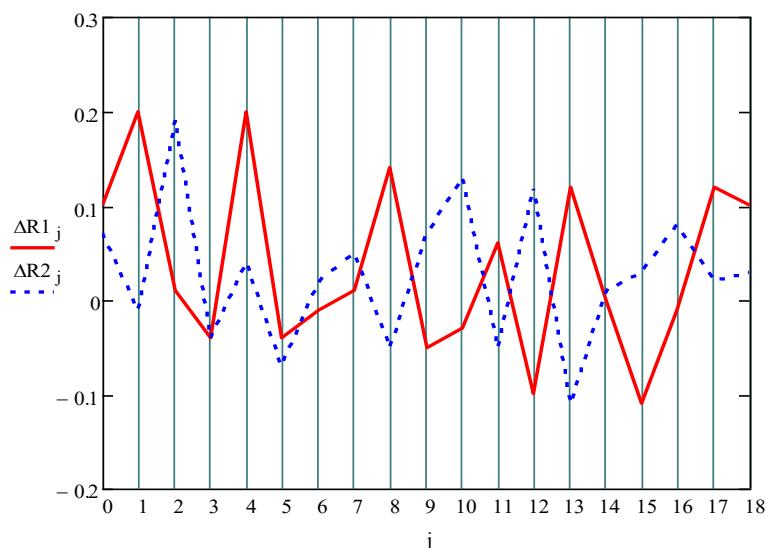


Рис. 4. Эпюры динамики показателей риска на выходе синергетических классификаторов от эпохи к эпохе

Fig. 4. Diagrams of the dynamics of risk indicators at the output of synergetic classifiers from epoch to epoch

Для обучения НС сформируем обучающую выборку пациентов с коморбидными заболеваниями, при этом будем кодировать наличие коморбидного заболевания единицей, а его отсутствие – нулем. В таком случае в выборке будут присутствовать пациенты, относящиеся к

четырем классам: 00, 01, 10 и 11. При этом к классу коморбидных пациентов относятся только пациенты с кодом 11, а пациенты с кодом 00 относятся к классу здоровых, т. е. не больных ни ВП, ни АГ. В таблице 1 представлена структура данных в обучающей выборке.

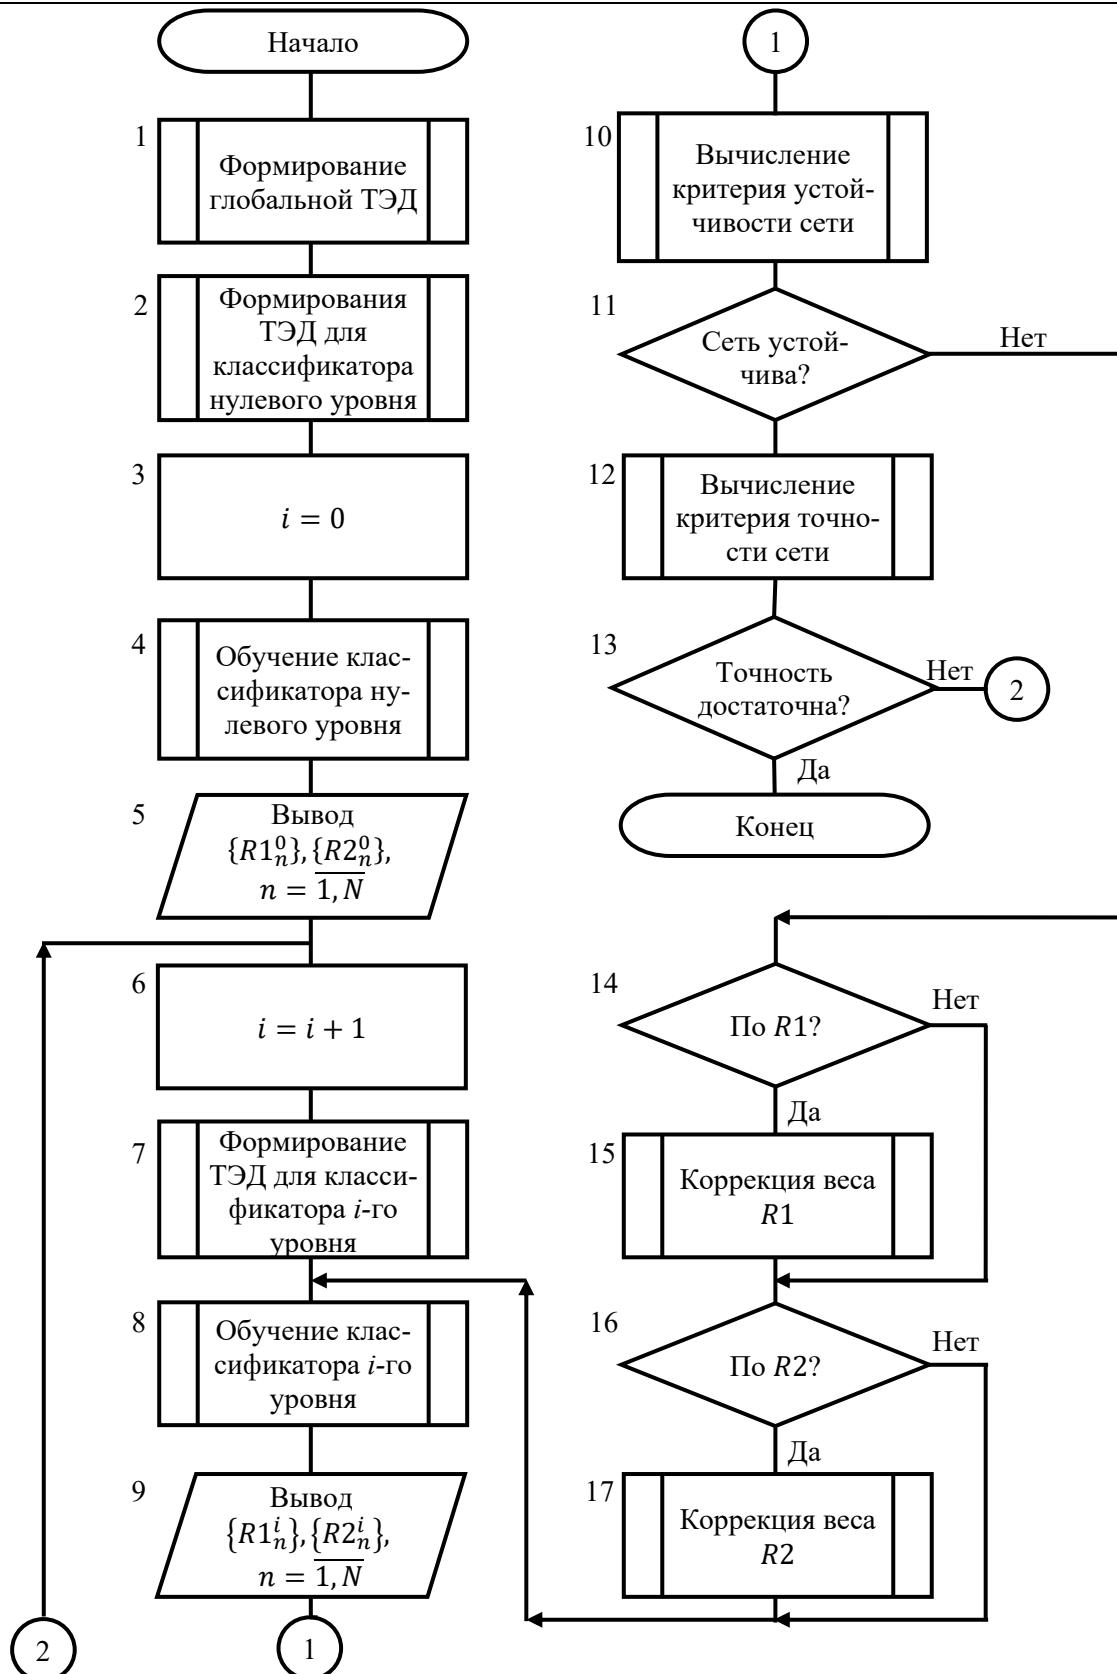


Рис. 5. Схема алгоритма синтеза синергетического классификатора

Fig. 5. Scheme of the synergistic classifier synthesis algorithm

Таблица 1. Структура данных в обучающей выборке для синергетического классификатора**Table 1.** Data structure in the training set for the synthesis of a synergetic classifier

№ п/п пациентов	Переменные модели классификатора				
	X1	X2	X3	R1	R2
1	***	***	***	0	1
2	***	***	***	0	0
3	***	***	***	1	0
...
n	***	***	***	1	1
...
N	***	***	***	0	1

После формирования таблицы 1 приступаем к обучению классификаторов риска $R1$ и $R2$ (схема алгоритма на рис. 5), структура которых представлена на рисунке 6. Эти классификаторы

назовем классификаторами нулевого уровня и обозначим их выходы как $R1^0$ и $R2^0$. Для их обучения необходимо из таблицы 1 сформировать две таблицы экспериментальных данных (ТЭД).

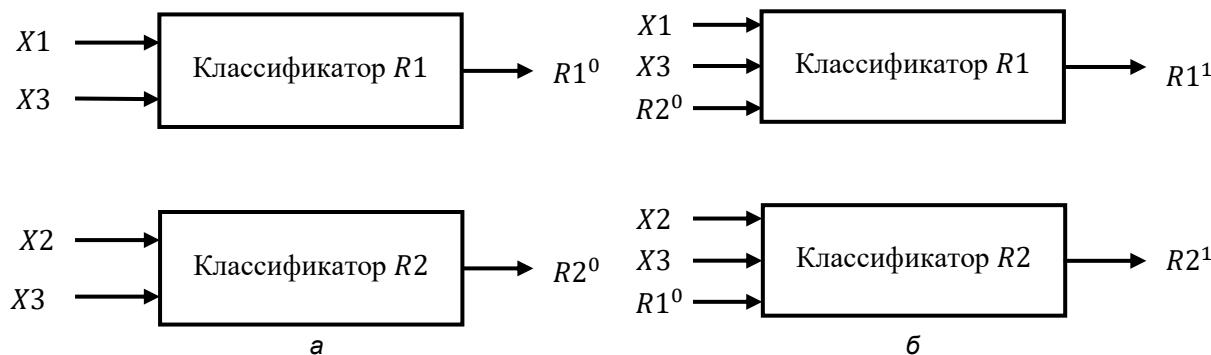


Рис. 6. Структурная схема синергетических классификаторов: а – для нулевого шага обучения; б – для первого и последующих шагов обучения

Fig. 6. Block diagram of synergetic classifiers: a – for the zero learning step; б – for the first and subsequent learning steps

Первая ТЭД предназначена для обучения классификатора риска $R1$, а вторая ТЭД – для классификатора риска $R2$. В первую ТЭД входят пациенты с кодами риска 00 и 10, а во вторую ТЭД – 00 и 01. При этом из первой ТЭД исключаются столбцы $X2$ и $R2$, а из второй ТЭД – столбцы $X1$ и $R1$.

После обучения классификаторов нулевого уровня, структура которых представлена на рисунке 6, а, переходим к обучению классификаторов первого уровня. Классификаторы первого уровня

построены по схеме (рис. 3) и объединены в один классификатор. Его схема представлена на рисунке 6, б.

В таблице 2 приведена структура данных для синергетических классификаторов первого уровня. Такую же структуру данных имеют классификаторы всех последующих уровней, которые строятся по аналогичной схеме с учетом того, что для классификатора i -го уровня на входы подаются риски, определенные классификатором $i-1$ -го уровня.

Таблица 2. Структура данных обучающей выборки для первого и последующих уровней**Table 2.** Structure of the training sample data for the first and subsequent levels

№ п/п пациентов	Переменные модели классификатора						
	X1	X2	X3	R1 ⁱ	R2 ⁱ	R1	R2
1	***	***	***	0,2	0,8	0	1
2	***	***	***	0,1	0,25	0	0
3	***	***	***	0,85	0,2	1	0
...
n	***	***	***	0,85	0,85	1	1
...
N	***	***	***	***	***	***	***

Для перехода к построению классификатора следующего уровня проверяются показатели качества классификации классификатора текущего уровня, а также проверяется устойчивость модели классификатора по следующим формулам:

$$K1_s = \frac{1}{\lambda+1} \sum_{k=s}^{s+\lambda} (\Delta R1_{k+1} \cdot \Delta R2_k), \quad (7)$$

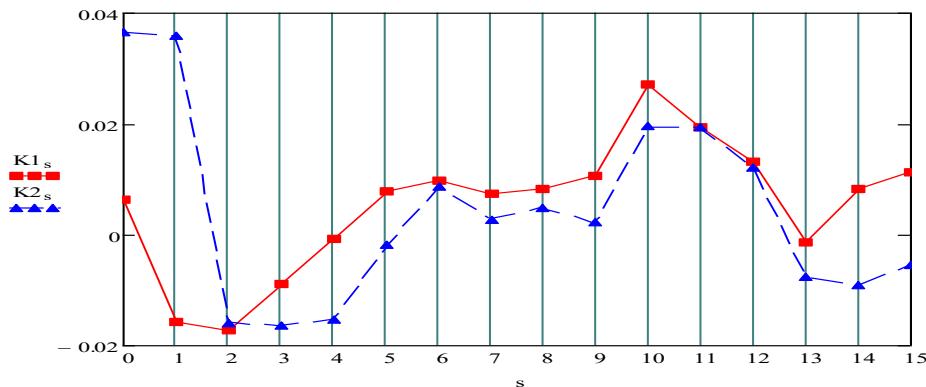
$$K2_s = \frac{1}{\lambda+1} \sum_{k=s}^{s+\lambda} (\Delta R1_k \cdot \Delta R2_{k+1}), \quad (8)$$

где $s=0 \dots i-2$; $\lambda=0$ при $i=2$, $\lambda=1$ при $i=3$, $\lambda=2$ при $i \geq 4$.

Показатели (7) и (8) определяются в блоке 10 алгоритма рисунка 5 и при неудовлетворительной устойчивости, т. е.

когда критерий устойчивости превышает пороговое значение, что показывает наличие положительной обратной связи; лицо, принимающее решение (ЛПР) в блоках 15 и 17, может ослабить ее влияние. На рисунке 7 показаны эпюры динамики показателей устойчивости модели классификатора от эпохи к эпохе. При удовлетворительной точности модели и при удовлетворении показателя критерия устойчивости процесс обучения НС с синергетическими каналами заканчивается.

Структурная схема ММК риска ВП, предназначенная для адаптивной БТС реабилитационного типа, учитывающая синергетический фактор, представлена ниже рисунок 8.

**Рис. 7.** Эпюры динамики показателей устойчивости модели классификатора от эпохи к эпохе**Fig. 7.** Diagrams of the dynamics of stability indicators of the classifier model from epoch to epoch

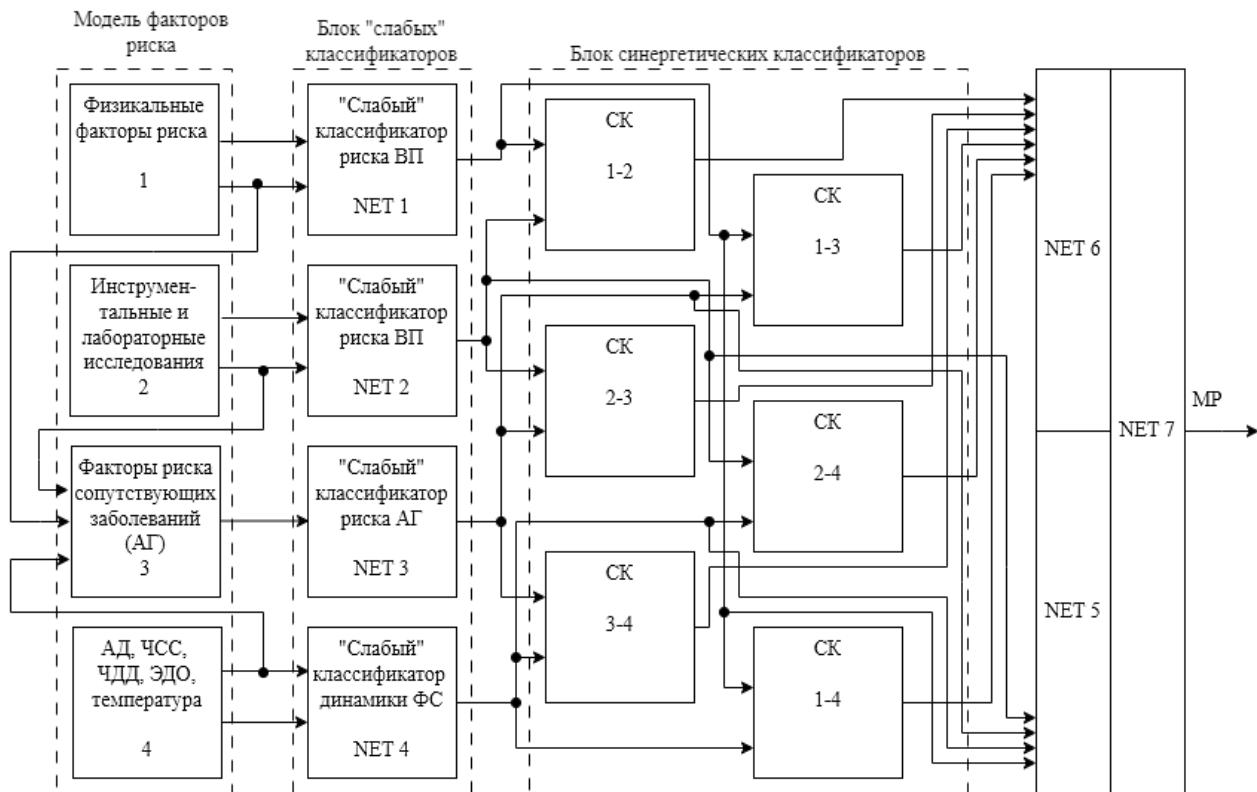


Рис. 8. Структурная схема модели мультимодального классификатора риска ВП

Fig. 8. Block diagram of the model of the multimodal risk classifier for community-acquired pneumonia

Среди ФР ВП выделяют более ста показателей. К наиболее значимым из них относят характер начала заболевания, степень дыхательной недостаточности, показатели АД, индекс массы тела (ИМТ), показатели рентгенографических исследований, показатели клинического анализа крови, возраст [12]. Что же касается ФР АГ, то, согласно исследованиям, проведенным в [18], к основным значимым ФР АГ были отнесены: возраст, курение, показатели АД, стресс, уровень холестерина, ИМТ, наследственность, атеросклероз и другие хронические заболевания.

В связи с этим в пространстве ФР было выделено четыре сегмента. Они разделены на «неизменяемые» (эти ФР в процессе лечения или реабилитации остаются постоянными и не влияют на

динамику риска заболевания) – сегменты 1...3 – и оперативные, которые могут «мгновенно» реагировать на изменение функционального состояния (ФС) – сегмент четыре. В первый сегмент ФР включены физикальные ФР, во второй – ФР, определяемые посредством инструментальных и лабораторных исследований [19].

Третий сегмент ФР ВП содержит предикторы риска сопутствующего заболевания, в качестве которого выбрана АГ. В сегменте четыре используются показатели, «моментально» реагирующие на экзогенные или эндогенные воздействия: АД, частота пульса (ЧСС), частота дыхательных движений (ЧДД), эндоцермальный ответ (ЭДО). Формирователи дескрипторов на основе ЭДО рассмотрены в [20].

Решения слабых классификаторов в ММК со структурой (рис. 8) агрегируются сильными классификаторами (strong classifiers) NET 5, NET 6, NET 7, которые могут быть построены на любой парадигме [12; 21]. Пример

структур агрегатора NET 5 показан ниже (рис. 9). Полагаем, что классификаторы нижнего иерархического уровня NET 1, NET 2, NET 3 и NET 4 дифференцируют риск ВП на три уровня: высокий, средний, низкий.

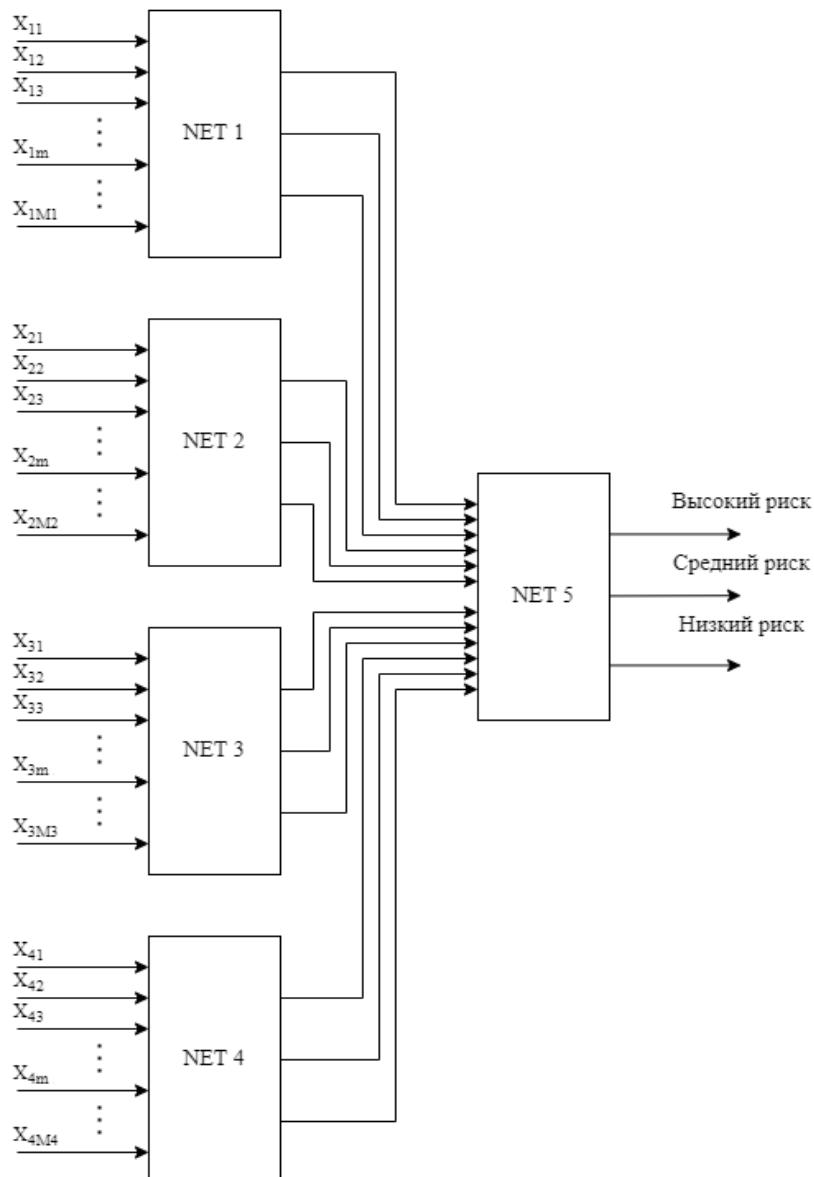


Рис. 9. Структурная схема нейронной сети в качестве классификатора риска внебольничной пневмонии

Fig. 9. Block diagram of a neural network as a risk classifier for community-acquired pneumonia

Для оценки риска ВП формируют четыре сегмента ФР (рис. 8), определяются соответствующие им дескрипторы, которые поступают на входы слабых

классификаторов NET 1, NET 2, NET 3 и NET 4. Например, для формирования дескриптора для слабого классификатора по функции принадлежности (ФП) ФР

x_1 – «возраст», которая представлена на рисунке 10, воспользуемся формулой Байеса:

$$\text{КУ}_{\text{ВП}}(x_1) = \frac{P_{\text{ВП}}(\text{фон}) \cdot P(x_1 | \text{ВП})}{P(x_1)}, \quad (9)$$

где $P_{\text{ВП}}(\text{фон})$ – априорная вероятность ВП по популяции; $P(x_1 | \text{ВП})$ – вероятность того, что возраст больного ВП в популяции равен x_1 ; $P(x_1)$ – гистограмма распределения возраста в популяции [13].

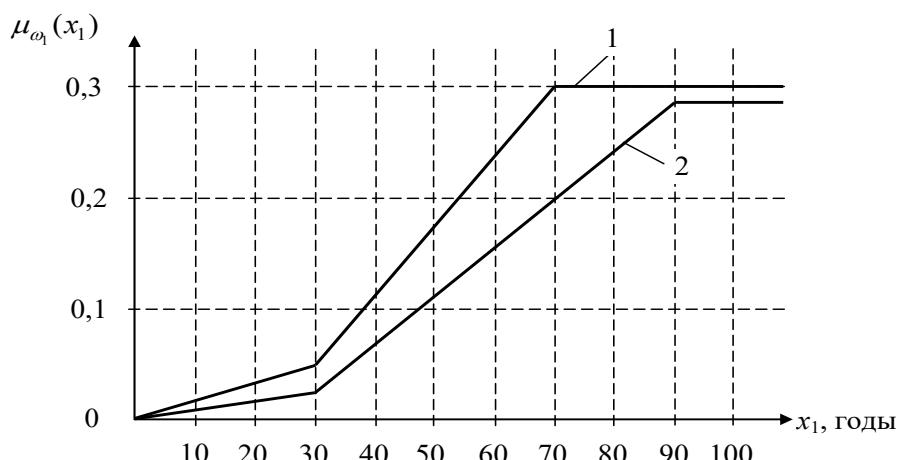


Рис. 10. Графики функций принадлежности по базовой переменной «возраст» к классу ω_1 – «ВП» для мужчин (1) и женщин (2)

Fig. 10. Graphs of membership functions for the basic variable "age" by class ω_1 – "C-AP" for men (1) and women (2)

Блоchно-иерархическая структура классификаторов (рис. 9) синтезируется в два этапа (схема алгоритма на рис. 11).

Сначала обучаются классификаторы NET 1...NET 4 по дескрипторам, определяемым, например, по формуле (9), а затем обучается NET 5. Структура

ТЭД для обучения классификаторов NET 1...NET 4 (рис. 9) представлена в таблице 3 (формируется в блоке 1 – рис. 11). Последний столбец таблицы 3 заполняется по результатам тестирования NET 1 и переносится в таблицу 4.

Таблица 3. Структура данных для обучения нейронных сетей NET 1...NET 4

Table 3. Data structure for training neural networks NET 1...NET 4

NN образцов	Вход 1 NET 1	Вход 2 NET 1	...	Вход M1 NET 1	Цель	Выход NET 1
1	$(X_{11})_1$	$(X_{12})_1$...	$(X_{1M1})_1$	0	0
2	$(X_{11})_2$	$(X_{12})_2$...	$(X_{1M1})_2$	1	1
.
.
L	$(X_{11})_L$	$(X_{12})_L$...	$(X_{1M1})_L$	1	1



Рис. 11. Схема алгоритма синтеза мультимодального классификатора риска внебольничной пневмонии

Fig. 11. Scheme of the synthesis algorithm for a multimodal risk classifier for community-acquired pneumonia

В таблице 4 представлена структура данных в обучающих и контрольных выборках для обучения НС второго

иерархического уровня (на рис. 9 это NET 5).

Таблица 4. Структура данных для обучения нейронной сети NET 5

Table 4. Data structure for training the NET 5 neural network

NN образцов	Выход NET 1	Выход NET 2	Выход NET 3	Выход NET 4	Цель
1	NET 1-1	NET 2-1	NET 3-1	NET 4-1	0
2	NET 1-2	NET 2-2	NET 3-2	NET 4-2	1
.
.
.
L	NET 1-L	NET 2-L	NET 3-L	NET 4-L	1

В блоках 2 и 3 выполняется обучение классификаторов NET 1...NET 4 по ТЭД со структурой таблицы 3. Последний столбец таблицы 3 заполняется после формирования контрольных выборок в блоке 4. По результатам их классификации NET 1...NET 4 формируют ТЭД для NET 5 (блоки 5, 6) со структурой таблицы 4. В блоке 7 осуществляется обучение классификатора NET 5.

Агрегатор NET 6 (рис. 8), аналогично NET 5 агрегирует решения СК. Каждый СК, так же как и классификаторы NET 1...NET 4 на рис. 9, имеет три выхода, соответствующие трем классам риска ВП. Решения NET 5 и NET 6 агрегируются в NET 7 (рис. 8). Алгоритмы настройки NET 5, NET 6 и NET 7 аналогичны алгоритму рисунка 11.

Для настройки НС использовался программный продукт *Neurowork*, разработанный в среде MATLAB на кафедре биомедицинской инженерии Юго-Западного государственного университета. Он включает в себя пять модулей, каждый из которых обеспечивает выполнение определенного этапа построения ММК [14; 22]. В качестве примера на рисунках 12 и 13 представлены интерфейсные окна двух из этих модулей. Модуль *GuiData* работает с обучающими и контрольными датасетами, предназначенными для обучения и валидизации ММК. Модуль *GuiNet* предназначен для обучения и тестирования НС, а также для классификации неизвестных образцов.

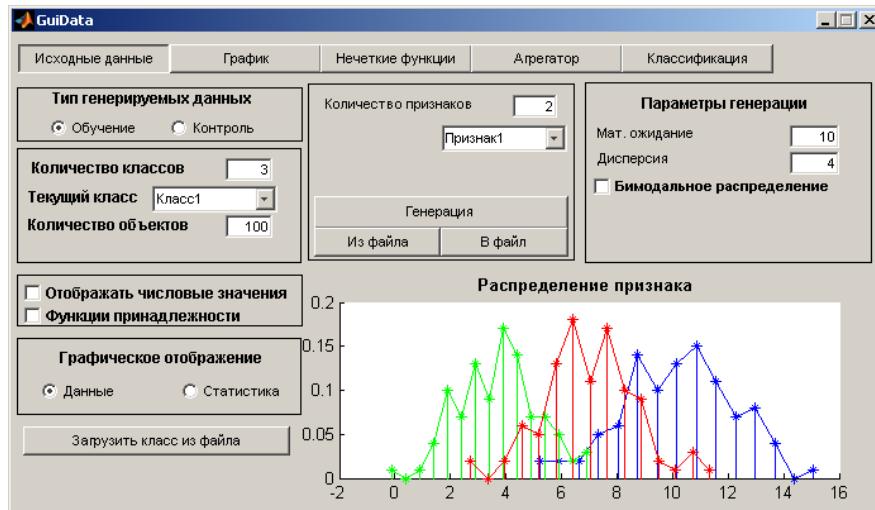


Рис. 12. Графический интерфейс модуля GuiData

Fig. 12. Graphical interface of the GuiData module

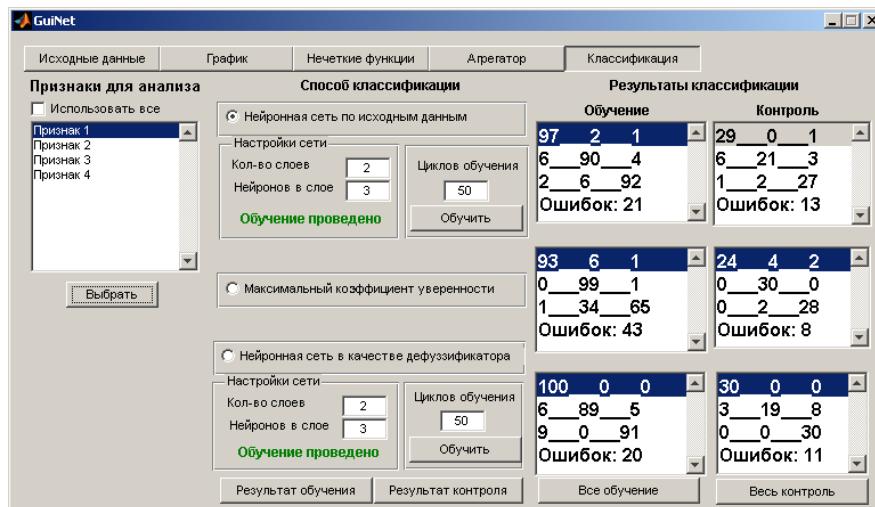


Рис. 13. Графический интерфейс модуля GuiNet

Fig. 13. Graphical interface of the GuiNet module

Глобальные параметры НС задаются в окне *GuiNet* (транспаранты ввода в центре окна). В локальных окнах в правой части интерфейсного окна выводятся показатели качества классификации по каждому классу для обучающей и тестовой выборок.

Результаты и их обсуждение

Для оценки показателей качества классификации разработанных ММК ВП: диагностической чувствительности

(ДЧ), диагностической специфичности (ДС) и диагностической эффективности (ДЭ) – была создана экспериментальная группа в количестве 400 пациентов. Экспериментальная группа формировалась по результатам ретроспективных исследований. Больные в экспериментальной группе были разделены по риску ВП на три класса. По 30% больных были отнесены к классам «высокий риск» и «средний риск», у 40% пациентов был установлен класс «низкий риск» ВП. При

стратификации групп на классы исходили из того, что в каждом классе должно быть не менее ста пациентов.

Диагностические характеристики ММК определялись для экспериментальной и контрольной выборок. Для оценки влияния на диагностические показатели ММК слабых классификаторов сопутствующих заболеваний, контрольная выборка формировалась из

пациентов с подтвержденным диагнозом АГ. Результаты классификации ММК ВП на обучающей выборке приведены в таблице 5 (в числителе). Результаты классификации риска ВП сравнивались с балльной шкалой PSI, на которой также были выделены три градации степени тяжести ВП (результаты приведены в знаменателе).

Таблица 5. Экспериментальные данные по классификации риска внебольничной пневмонии на обучающей выборке

Table 5. Experimental data on the risk classification of community-acquired pneumonia on the training set

Обследуемые	Высокий риск	Средний риск	Низкий риск
$n_{\omega_1}^1 = 120$ (высокий риск)	101/84	19/28	0/8
$n_{\omega_2}^2 = 120$ (средний риск)	11/23	99/85	10/12
$n_{\omega_3}^3 = 160$ (низкий риск)	5/16	25/28	130/116
Всего	117/123	143/141	140/136

Сравнение показателей качества классификации ММК при классификации АГ как с прототипом осуществлялось с известной шкалой риска ССЗ SCORE [6; 7]. Высокий риск АГ соответствовал риску по шкале SCORE более 10%, а низкий – менее одного процента.

Средний риск соответствовал участку шкалы SCORE между этими диапазонами. Показатели качества классификации АГ для модели ММК (числитель) и шкалы SCORE знаменатель, используемые в качестве аналога, представлены ниже (табл. 6).

Таблица 6. Показатели качества классификации артериальной гипертензии на обучающей и контрольной выборках мультиомодального классификатора и шкалы SCORE

Table 6. Quality indicators for the classification of arterial hypertension on the training and control samples of the multimodal classifier and the SCORE scale

Класс	Обучающая выборка			Контрольная выборка		
	ДЧ,%	ДС,%	ДЭ,%	ДЧ,%	ДС,%	ДЭ,%
$n_{\omega_1}^1$	84/70	96/86	82,5/71	82/71	96/87	87/73
$n_{\omega_1}^2$	82,5/71	80/80		84/70	90/81	
$n_{\omega_1}^3$	81/72,5	92/90,2		84/73	95/92	

Таким образом, модель ММК по всем показателям качества классификации на всех экспериментальных и контрольных группах пациентов достигает величины не менее 0,8. Показатели качества классификации ММК по классификации риска АГ в среднем выше, чем у известной системы SCORE, на 11%, что позволяет рекомендовать их для использования в системах мониторинга и контроля эффективности терапии и реабилитации пациентов с кардиореспираторными заболеваниями.

Выводы

1. Разработан метод синтеза классификатора риска внебольничной пневмонии с учетом коморбидности, отличающийся тем, что синергетический эффект на риск внебольничной пневмонии сочетанного заболевания учитывается вводом дополнительных (виртуальных) факторов риска, представленных нелинейной моделью реальных факторов риска, с последующим синтезом слабых классификаторов на их основе, позволяющий построить мультимодальный классификатор риска внебольничной пневмонии, учитывать взаимное влияние коморбидных заболеваний на суммарный риск кардиореспираторного заболевания.

2. Для построения слабых классификаторов, позволяющих учесть эффект взаимовлияния коморбидных заболеваний на их риски, предложено использовать полносвязную нейронную сеть Хопфилда, отличающуюся многосвязной структурой и двумя задержками на один такт, управляемыми параллельным генератором с противофазными выходами, обеспечивающими запись в регистры задержек рисков с выходов нейронной сети Хопфилда со сдвигами на один такт.

3. Разработан алгоритм обучения слабого классификатора со структурой нейронной сети Хопфилда, позволяющий обеспечить заданные показатели

точности классификации при заданных показателях устойчивости нейронной сети.

4. Предложен критерий устойчивости нейронной сети Хопфилда с многосвязной структурой, заключающийся в вычислении суммы приращений рисков на ее выходах на апертуре трех эпох обучения и контроле выхода этого показателя за пределы пороговой величины.

5. Разработан мультимодальный классификатор риска внебольничной пневмонии, предназначенный для мониторинга функционального состояния пациента в процессе проведения терапевтических и реабилитационных процедур, состоящий из трех макрослоев автономных интеллектуальных агентов. Первый макрослой содержит три слабых классификатора риска внебольничной пневмонии. Для первого слабого классификатора формируются дескрипторы из данных физикального обследования. Второй слабый классификатор использует дескрипторы, полученные по результатам инструментальных и лабораторных исследований, первый из которых осуществляет анализ данных, полученных на основе физикальных исследований, второй – на основе инструментальных и лабораторных исследований, а третий – анализирует факторы риска, изменяющиеся в процессе экзогенного воздействия. Также в первом макрослое сформирован слабый классификатор сопутствующего заболевания (артериальной гипертензии) по факторам риска, совпадающим с факторами риска основного заболевания. Второй макрослой слабых классификаторов формируется синергетическими каналами, а третий макрослой агрегирует решения слабых классификаторов первых двух макрослоев.

6. Проведены исследования показателей качества классификации риска внебольничной пневмонии посредством

мультимодального классификатора на ретроспективных данных. При использовании оптимальной конфигурации мультиомодального классификатора все показатели качества классификации

были не менее 0,8 и превысили показатели качества шкал PSI и SCORE в одних и тех же контрольных группах в среднем на 11%.

Список литературы

1. Абрамович С. Г., Игнатьева Т. Г. Методы аппаратной физиотерапии в лечении ишемической болезни сердца // Сибирский медицинский журнал. 2003. Т. 37, № 2. С. 4–9.
2. Соболева Л. Р., Кузяев А. И. Осложнения у больных внегоспитальной пневмонией с летальным исходом // Международный конгресс по болезням органов дыхания. СПб., 1998. С. 24–26.
3. Результаты проспективного наблюдения больных артериальной гипертонией с сопутствующими хроническими болезнями органов дыхания в рутинной практике. Часть I. Характеристика неблагоприятных событий / М. И. Смирнова, А. С. Курехян, В. М. Горбунов, Г. Ф. Андреева, Я. Н. Кошелевская, А. Д. Деев // Кардиоваскулярная терапия и профилактика. 2022. № 21 (10). С. 3383. <https://doi.org/10.15829/1728-8800-2022-3383>
4. Прогнозирование и оценка степени тяжести ишемии сердца на основе гибридных нечётких моделей / И. А. Комлев, О. В. Шаталова, С. В. Дегтярев, А. В. Серебровский // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9, № 1 (30). С. 133–145.
5. Виртуальные потоки в гибридных решающих модулях классификации сложноструктуримых данных / А. В. Киселев, Д. Ю. Савинов, С. А. Филист, О. В. Шаталова, В. В. Жилин // Прикаспийский журнал: Управление и высокие технологии. 2018. № 2 (42). С. 137–149.
6. Методы и алгоритмы формирования слабых классификаторов в ансамбле классификаторов прогнозирования сердечно-сосудистых рисков / З. У. Протасова, О. В. Шаталова, А. А. Б. Дафалла, С. В. Дегтярев // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9, № 3 (32). С. 64–83.
7. Шаталова О. В., Медников Д. А., Протасова З. У. Мультиагентная интеллектуальная система для прогноза риска сердечно-сосудистых осложнений с синергетическими каналами // Системный анализ и управление в биомедицинских системах. 2020. Т. 19, № 3. С. 177–188.
8. Модели латентных предикторов в интеллектуальных системах прогнозирования состояния живых систем / А. В. Киселев, О. В. Шаталова, З. У. Протасова, С. А. Филист, Н. С. Стадниченко // Известия Юго-Западного государственного университета. Серия:

Управление, вычислительная техника, информатика. Медицинское приборостроение. 2020. Т. 10, № 1. С. 114–133.

9. Heterogeneous Classifiers with Virtual Flows in Intelligent Systems for Predicting Cardiovascular Complications During the Rehabilitation Period / E. V. Petrunina, O. V. Shatalova, D. S. Zabanov, V. V. Serebrovskii // Biomedical Engineering. 2020. Vol. 54, N 3. P. 212–215. <https://doi.org/10.1007/s10527-020-10006-6>

10. Prediction of the Risk of Cardiovascular Complications with a Segmented Space of Risk Factors and Synergy Channels / O. V. Shatalova, D. A. Mednikov, Z. U. Protasova, N. S. Stadnichenko // Journal of Physics: Conference Series: II International scientific conference on applied physics, information technologies and engineering (APITECH II) (25 September – 04 October 2020 y.). Krasnoyarsk: Institute of Physics and IOP Publishing Limited, 2020. P. 32042. <https://doi.org/10.1088/1742-6596/1679/3/032042>

11. Нейросетевой решающий модуль для исследования живых систем / С. Г. Емельянов, А. Ф. Рыбочкин, С. А. Филист, А. Р. Халед // Известия Курского государственного технического университета. 2008. № 2 (23). С. 77–82.

12. Гибридный нейронечеткий классификатор для мониторинга эффективности лечения заболеваний системы дыхания с учетом коморбидности / Е. В. Петрунина, С. А. Филист, Л. В. Шульга, В. В. Песок, Хайдер А. Х. Алавси, А. В. Бутусов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 4. С. 27–53. <https://doi.org/10.21869/2223-1536-2023-13-4-27-53>

13. Модели нечетких нейронных сетей с трехстабильным выходом в инструментарии для психологических и физиологических исследований / С. А. Филист, Х. А. Р. Салем, О. В. Шаталова, В. В. Руденко // Системный анализ и управление в биомедицинских системах. 2007. Т. 6, № 2. С. 475–479.

14. A Method for Creating Fuzzy Neural-Network Models Using the Matlab Package for Biomedical Applications / V. V. Zhilin, S. A. Filist, K. A. Rakhim, O. V. Shatalova // Biomedical Engineering. 2008. Vol. 42, N 2. P. 64–66. <https://doi.org/10.1007/s10527-008-9019-y>

15. Гибридные нечеткие модели для прогнозирования возникновения и осложнений артериальной гипертензии с учетом энергетических характеристик биоактивных точек / М. А. Ефремов, С. А. Филист, О. В. Шаталова, Е. А. Старцев, Л. В. Шульга // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2018. Т. 8, № 4 (29). С. 104–119.

16. 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.

17. Филист С. А., Томакова Р. А., Яа З. Д. Универсальные сетевые модели для задач классификации биомедицинских данных // Известия Юго-Западного государственного университета. 2012. № 4 (43), ч. 2. С. 44–50.
18. Prediction of Coronary Risk Using a Multichannel System with Redundant Decisions and Associative Choice / E. V. Petrunina, O. V. Shatalova, Z. U. Protasova, A. F. Rybochkin, V. V. Serebrovsky // Biomedical Engineering. 2020. Vol. 54, N 2. P. 140–144. <https://doi.org/10.1007/s10527-020-09991-5>
19. Вклад комбинаций факторов риска в развитие хронических неинфекционных заболеваний / О. С. Кобякова, Е. А. Старовойтова, И. В. Толмачев [и др.] // Социальные аспекты здоровья населения. 2020. № 66 (5). С. 1. <https://doi.org/10.21045/2071-5021-2020-66-5-1>
20. Диагностические системы на основе анализа вольтамперных характеристик биоактивных точек / Н. А. Кореневский, С. А. Филист, О. В. Шаталова, К. Д. А. Кассим, В. В. Руденко // Биотехносфера. 2013. № 5 (29). С. 33–38.
21. Волков И. И., Емельянов С. Г., Филист С. А. Метод классификации сложных объектов на основе анализа структурных функций медленных волн // Биомедицинская радиоэлектроника. 2012. № 4. С. 6–12.
22. Биотехническая система с виртуальной реальностью в реабилитационных комплексах с искусственными обратными связями / А. А. Трифонов, Е. В. Петрунина, С. А. Филист, А. А. Кузьмин, В. В. Жилин // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9, № 4. С. 49–66.

References

1. Abramovich S.G., Ignat'eva T.G. Methods of Hardware Physiotherapy in the Treatment of Coronary Heart Disease. *Sibirskiy meditsinskiy zhurnal = Siberian Medical Journal*. 2003;37(2):4–9. (In Russ.)
2. Soboleva L.R., Kuzyaev A.I. Complications in Patients with Community-Acquired Pneumonia with Fatal Outcome. In: *Mezhdunarodnyi kongress po boleznyam organov dyhaniya = International Congress for Respiratory Diseases*. St. Petersburg; 1998. P. 24–26. (In Russ.)
3. Smirnova M.I., Kurekhyan A.S., Gorbunov V.M., Andreeva G.F., Koshelyaevskaya Y.N., Deev A.D. Prospective Follow-Up of Hypertensive Patients with Concomitant Chronic Respiratory Diseases in Routine Practice. Part I. Characterization of Adverse Events]. *Kardiovaskulyarnaya terapiya i profilaktika = Cardiovascular Therapy and Prevention*. 2022;21(10):3383. (In Russ.) <https://doi.org/10.15829/1728-8800-2022-3383>
4. Komlev I.A., Shatalova O.V., Degtyaryov S.V., Serebrovskiy A.V. Prediction and Assessment of Severity of Cardiac Ischemia, Based on Hybrid Fuzzy Models. *Izvestiya Yugo-*

Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2019;9(1):133–145. (In Russ.)

5. Kiselev A.V., Savinov D.Y., Filist S.A., Spatalova O.V., Zpilin V.V. Virtual Flows in Hybrid Decision Modules of Classification of Complex-Structured Data. *Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii = The Caspian Journal: Management and High Technologies.* 2018;2(42):137–149. (In Russ.)

6. Protasova Z.U., Shatalova O.V., Dafalla A.A.B., Degtyaryov S.V. Methods and Algorithms for the Formation of Weak Classifiers in the Ensemble of Classifiers for Predicting Cardiovascular Risk. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering.* 2019;9(3):64–83. (In Russ.)

7. Shatalova O.V., Mednikov D.A., Protasova Z.U. Mul'tiagentnaya intellektual'naya sistema dlya prognoza riska serdechno-sosudistykh oslozhneniy s sinergeticheskimi kanalami [Multi-Agent Intelligent System for Prediction of Risk of Cardiovascular Complications with Synergy Channels]. *Sistemnyy analiz i upravlenie v biomeditsinskikh sistemah = System Analysis and Management in Biomedical Systems.* 2020;19(3):177–188. (In Russ.)

8. Kiselev A.V., Shatalova O.V., Protasova Z.U., Filist S.A., Stadnichenko N.S. Models of Latent Predictors in Intellectual Systems for Forecasting the State of Living Systems. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering.* 2020;10(1):114–133. (In Russ.)

9. Petrunina E.V., Shatalova O.V., Zabanov D.S., Serebrovskii V.V. Heterogeneous Classifiers with Virtual Flows in Intelligent Systems for Predicting Cardiovascular Complications during the Rehabilitation Period. *Biomedical Engineering.* 2020;54(3):212–215. <https://doi.org/10.1007/s10527-020-10006-6>

10. Shatalova O.V., Mednikov D.A., Protasova Z.U., Stadnichenko N.S. Prediction of the risk of cardiovascular complications with a segmented space of risk factors and synergy channels. In: *Journal of Physics: Conference Series: II International scientific conference on applied physics, information technologies and engineering (APITECH II), 25 September – 04 October 2020.* Krasnoyarsk: Institute of Physics and IOP Publishing Limited; 2020. P. 32042. <https://doi.org/10.1088/1742-6596/1679/3/032042>

11. Emel'yanov S.G., Rybochkin A.F., Filist S.A., Haled A.R. Neural Network Solver Module for the Study of Living Systems. *Izvestiya Kurskogo gosudarstvennogo*

tekhnicheskogo universiteta = Proceedings of Kursk State Technical University. 2008;(2):77–82. (In Russ.)

12. Petrunina E.V., Filist S.A., Shulga L.V., Pesok V.V., Alawsi Hayder A.H., Butusov A.V. Hybrid Neuro-Fuzzy Classifier for Monitoring the Effectiveness of Treatment of Diseases of the Respiratory System, Taking into Account Comorbidity. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoе priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2023;13(4):27–53. (In Russ.)* <https://doi.org/10.21869/2223-1536-2023-13-4-27-53>

13. Filist S.A., Salem H.A.R., Shatalova O.V., Rudenko V.V. Modeli nechetkih neyronnyh setey s trekhstabil'nym vyhodom v instrumentarii dlya psihologicheskikh i fiziologicheskikh issledovaniy [Slipshod Neuron Networks, Having Three Stable Output, for Diagnostics of Psychical Diseases]. *Sistemnyy analiz i upravlenie v biomeditsinskikh sistemah = System Analysis and Management in Biomedical Systems. 2007;6(2):475–479. (In Russ.)*

14. Zhilin V.V., Filist S.A., Rakhim K.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. https://doi.org/10.1007/s10527-008-9019-y*

15. Efremov M.A., Filist S.A., Shatalova O.V., Startsev E.A., Shulga L.V. Method for Constructing Hybrid Fuzzy Models for Predicting the Occurrence and Complications of Arterial Hypertension in Drivers of Vehicles Taking into Account the Energy Characteristics of Bioactive Points. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoе priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering. 2018;8(4):104–119. (In Russ.)*

16. Kudryavtsev P.S., Shutkin A.N., Protasova V.V., Filist S.A. Structural Functional Model for Monitoring the Influence of Control Actions on Self-Organizing Systems State. *Prikaspischiy zhurnal: upravlenie i vysokie tekhnologii = The Caspian Journal: Management and High Technologies. 2015;(2):105–118. (In Russ.)*

17. Filist S.A., Tomakova R.A., Yaa Z.D. Universal Network Models for Classification of Biomedical Data. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of Southwest State University. 2012;(4):44–50. (In Russ.)*

18. Petrunina E.V., Shatalova O.V., Protasova Z.U., Rybochkin A.F., Serebrovsky V.V. Prediction of Coronary Risk Using a Multichannel System with Redundant Decisions and Associative Choice. *Biomedical Engineering. 2020;54(2):140–144. https://doi.org/10.1007/ s10527-020-09991-5*

19. Kobyakova O.S., Starovoytova E.A., Tolmachev I.V., et al. Contribution of Combined Risk Factors into Development of Chronic Non-Communicable Diseases. *Sotsial'nye aspekty*

zdorov'ya naseleniya = Social aspects of Population Health. 2020;(66):1. (In Russ.)
<https://doi.org/10.21045/2071-5021-2020-66-5-1>

20. Korenevskiy N.A., Filist S.A., Shatalova O.V., Kassim K.D.A., Rudenko V.V. Diagnostic Systems Based on Analysis of Current-Voltage Characteristics of Bioactive Points. *Biotehnosfera = Biotechnosphere.* 2013;(5):33–38. (In Russ.)

21. Volkov I.I., Emel'yanov S.G., Filist S.A. Complicated Objects Classification Method Based on Analysis of Structural Functions of Slow Waves. *Biomeditsinskaya radioelektronika = Journal Biomedical Radioelectronics.* 2012;4:6–12. (In Russ.)

22. Trifonov A.A., Petrunina E.V., Filist S.A., Kuzmin A.A., Zhilin V.V. Biotechnical System with Virtual Reality in Rehabilitation Complexes with Artificial Feedback. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Serija: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoje priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering.* 2019;9(4):49–66. (In Russ.)

Информация об авторах / Information about the Authors

Петрунина Елена Валерьевна, кандидат технических наук, доцент, заведующий кафедрой СМАРТ-технологий, Московский политехнический университет, г. Москва, Российская Федерация, e-mail: isu@mospolytech.ru, ORCID: 0000-0003-3661-0778

Elena V. Petrunina, Candidate of Sciences (Engineering), Associate Professor, Head of the Department of SMART Technologies, Moscow Polytechnic University, Moscow, Russian Federation, e-mail: isu@mospolytech.ru, ORCID 0000-0003-3661-0778

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

Алавси Хайдер Али Хуссейн, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: book.hp.2015@gmail.com, ORCID: 0009-0007-5635-2493

Hayder Ali H. Alawsi, Post-Graduate Student of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: book.hp.2015@gmail.com, ORCID: 0009-0007-5635-2493

Песок Валерия Вячеславовна, аспирант
кафедры биомедицинской инженерии,
Юго-Западный государственный университет,
г. Курск, Российская Федерация,
e-mail: lera.pesok@mail.ru,
ORCID: 0009-0006-9843-3809

Кузьмин Александр Алексеевич, кандидат
технических наук, доцент, доцент кафедры
биомедицинской инженерии, Юго-Западный
государственный университет,
г. Курск, Российская Федерация,
e-mail: Ku3bmin@gmail.com,
Researcher ID: F-8405-2013,
ORCID: 0000-0001-7980-0673

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

Valeriya V. Pesok, Post-Graduate Student
of the Department of Biomedical Engineering,
Southwest State University,
Kursk, Russian Federation,
e-mail: lera.pesok@mail.ru,
ORCID: 0009-0006-9843-3809

Alexander A. Kuzmin, Candidate of Sciences
(Engineering), Associate Professor, Associate
Professor of the Department of Biomedical
Engineering, Southwest State University,
Kursk, Russian Federation,
e-mail: Ku3bmin@gmail.com,
Researcher ID: F-8405-2013,
ORCID: 0000-0001-7980-0673

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