

<https://doi.org/10.21869/2223-1536-2023-13-4-27-53>

УДК 004.8.032.26

Гибридный нейронечеткий классификатор для мониторинга эффективности лечения заболеваний системы дыхания с учетом коморбидности

Е. В. Петрунина¹, С. А. Филист² ✉, Л. В. Шульга²,
В. Песок², Хайдер А. Х. Алавси², А. В. Бутусов²

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

² Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305000, Российская Федерация

✉ e-mail: SFilist@gmail.com

Резюме

Цель исследования – разработка гибридного нейронечеткого классификатора для дистанционного контроля степени тяжести внебольничной пневмонии с учетом риска сопутствующих заболеваний.

Методы. Для оценки степени тяжести внебольничной пневмонии и определения эффективности ее плана лечения в гибридный нейронечеткий классификатор включена гибридная нейронная сеть, которая содержит три макрослоя: PNN-FNN-FNN*. Число решающих блоков макрослоя PNN равно числу сегментов, выделенных в пространстве информативных признаков, а на выходе каждого блока PNN выдаются оценки риска и отсутствия риска внебольничной пневмонии по кластерам степени тяжести. Агрегация принимаемых решений по N сегментам пространства информативных признаков осуществляется в слое FNN, который имеет структуру нечеткого модуля принятия решений. Агрегация $2L$ выходов PNN-FNN происходит в макрослое FNN*. В этом же макрослое учитывается влияние коморбидности на степень тяжести внебольничной пневмонии.

Результаты. Апробация гибридного нейронечеткого классификатора степени тяжести внебольничной пневмонии проведена на экспериментальной группе больных внебольничной пневмонией с коморбидностью в виде ишемической болезни сердца. Показатели качества классификации степени тяжести пневмонии с учетом риска коморбидного заболевания на примере ишемической болезни сердца показали, что агрегация классификатора степени тяжести внебольничной пневмонии и классификатора риска коморбидного заболевания в виде гибридного нейронечеткого классификатора позволяет повысить качество оценки степени тяжести внебольничной пневмонии более чем на 10% по всем показателям качества.

Заключение. Гибридный нейронечеткий классификатор, построенный на разных парадигмах распознавания образов, позволяет выделять кластеры тяжести заболевания и повысить показатели качества классификации степени тяжести внебольничной пневмонии при наличии коморбидности в среднем на 12%.

Ключевые слова: внебольничная пневмония; мониторинг и прогнозирование степени тяжести заболевания; коморбидность; нейронечеткий классификатор; нечеткий логический вывод; поддержка принятия врачебных решений.

Финансирование: Исследования выполнены 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: Формализованное информационное описание для медицинской экспертной системы / Е. В. Петрунина, С. А. Филист, Л. В. Шульга, В. Песок, Хайдер А. Х. Алапси, 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>.

Поступила в редакцию 04.10.2023

Подписана в печать 03.11.2023

Опубликована 22.12.2023

Hybrid Neuro-Fuzzy Classifier for Monitoring the Effectiveness of Treatment of Diseases of the Respiratory System, Taking into Account Comorbidity

Elena V. Petrunina¹, Sergey A. Filist² ✉, Leonid V. Shulga², Valeriya Pesok², Hayder A. H. Alawsi², Andrey V. Butusov²

¹ Moscow Polytechnic University
38 B. Semenovskaya Str., Moscow 107023, Russian Federation

² Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: SFilist@gmail.com

Abstract

The purpose of research is to develop a hybrid neuro-fuzzy classifier for remote monitoring of the severity of community-acquired pneumonia, taking into account the risk of concomitant diseases.

Methods. To assess the severity of community-acquired pneumonia and determine the effectiveness of its treatment plan, a hybrid neural network is included in the hybrid neuro-fuzzy classifier, which contains three macrolayers: PNN-FNN-FNN*. The number of decisive blocks of the PNN macrolayer is equal to the number of segments allocated in the space of informative features, and the output of each PNN block produces risk and non-risk assessments of community-acquired pneumonia by severity clusters. Aggregation of decisions made over N segments of the space of informative features is carried out in the FNN layer, which has the structure of a fuzzy decision-making module. The aggregation of 2L PNN-FNN outputs occurs in the FNN* macrolayer. The same macrolayer takes into account the influence of comorbidity on the severity of community-acquired pneumonia.

Results. The testing of a hybrid neuro-fuzzy classifier of the severity of community-acquired pneumonia was carried out on an experimental group of patients with community-acquired pneumonia with comorbidity in the form of coronary heart disease. Indicators of the quality of classification of the severity of pneumonia taking into account the risk of comorbid disease using the example of coronary heart disease showed that the aggregation of the classifier of the severity of community-acquired pneumonia and the classifier of the risk of comorbid disease in the form of a hybrid neuro-fuzzy classifier makes it possible to improve the quality of assessing the severity of community-acquired pneumonia by more than 10% for all quality indicators.

Conclusion. A hybrid neuro-fuzzy classifier, built on different pattern recognition paradigms, makes it possible to identify clusters of disease severity and improve the quality indicators for classifying the severity of community-acquired pneumonia in the presence of comorbidity by an average of 12%.

Keywords: community-acquired pneumonia; monitoring and forecasting the severity of the disease; comorbidity; neuro-fuzzy classifier; fuzzy logical inference; medical decision support.

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

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

For citation: Petrunina E. V., Filist S. A., Shulga L. V., Pesok V., Hayder A. H. Alawsi, Butusov A. V. Formalized Information Description for a Medical Expert System. *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*. 2023; 13(4): 27–53. (In Russ.) <https://doi.org/10.21869/2223-1536-2023-13-4-27-53>.

Received 04.10.2023

Accepted 03.11.2023

Published 22.12.2023

Введение

Патология системы дыхания в форме внебольничной пневмонии (ВБП) занимает лидирующее положение среди болезней органов дыхания [1; 2]. При амбулаторном лечении ВБП врачу необходимо принимать важные решения, связанные с госпитализацией больного, а также с оценкой эффективности плана лечения. Для формализации решения о госпитализации в медицинской практике используют ряд шкал оценки степени тяжести ВБП. Однако они включают множество факторов риска, которые трудно контролировать в процессе ведения больного в амбулаторных условиях. Второй проблемой классификации степени тяжести пневмонии являются коморбидные заболевания и схожесть их факторов риска с риском ВБП.

В настоящее время предпринимается множество попыток построить математические модели степени тяжести ВБП. Наиболее известные многомерные линейные модели и модели логистической регрессии [3; 4]. Для определения значимости каждого информативного признака в модель используются

различные критерии. Однако такие модели не удовлетворяют специалистов, так как врачи, как правило, работают с нечеткими данными, что вызывает проблемы при их дефазификации, и модели многомерной регрессии требуют знания четких значений входных переменных. Поэтому пристальное внимание исследователей привлекают нейронечеткие сети [5; 6; 7; 8; 9]. Они основываются на нечетких правилах и алгоритмах в отличие от традиционных классификаторов, которые используют бинарные или действительные значения входных переменных. Однако проблема обучения таких сетей пока не решена, поэтому в представленном исследовании принято решение комбинировать в одной структуре как нечеткие сети, так и обучаемые полносвязные нейронные сети (НС).

Материалы и методы

Модели классификаторов медицинского риска

Для реализации моделей мониторинга тяжести заболевания и эффективности лечения на основе гибридного нейронечеткого классификатора (ГНК)

используются многоагентные структуры. При этом каждый автономный интеллектуальный агент (АИА) работает со своим пространством информативных признаков (ПИП). Для построения АИА используем вероятностные нейронные сети (PNN) [10; 11]. Агрегацию решений PNN по M группам ПИП осуществляет нечеткая нейронная сеть (FNN) [5; 12; 13; 14; 15].




Рис. 1. Структура многоагентной системы классификации

Fig. 1. Structure of a multi-agent classification system

Макрослой PNN построен по блочному принципу, в соответствии с которым каждый блок PNN является дихотомическим классификатором и относит неизвестный образец либо к «своему» кластеру ω_ℓ , либо к кластеру «все остальное» $\bar{\omega}_\ell$. Число решающих блоков PNN в макрослое PNN определяется количеством M используемых ПИП, и каждый блок PNN выделяет L кластеров степени тяжести ВБП. Поэтому на выходе каждого блока PNN $_i$ имеем L двухкомпонентных векторов, первые компоненты которых показывают вероятности P_{ω_ℓ} для кластера ω_ℓ , а вторые –

В задачу ГНК входит интеграция накопленного практического опыта диагностики ВБП по сегментам ПИП. Использование одной многослойной НС для классификации таких данных сложно [5; 16]. На рисунке 1 представлена упрощенная структура классификатора PNN-FNN с разделением пространства предикторов на M сегментов.

вероятности $P_{\bar{\omega}_\ell}$ для альтернативного кластера $\bar{\omega}_\ell$ (в общем случае $P_{\omega_\ell} + P_{\bar{\omega}_\ell} \neq 1$).

Вероятности $P_{\omega_\ell}(X_i)$ и $P_{\bar{\omega}_\ell}(X_i)$ определены, согласно [5; 10], по следующим формулам:

$$P_{\omega_\ell}(X_i) = \sum_{j=1}^{\lambda_{\omega_\ell}} \exp \left(\frac{-\|X_i - X_{i\omega_\ell}^j\|^2}{\sigma^2} \right), \quad (1)$$

$$P_{\bar{\omega}_\ell}(X_i) = \sum_{j=1}^{\lambda_{\bar{\omega}_\ell}} \exp \left(\frac{-\|X_i - X_{i\bar{\omega}_\ell}^j\|^2}{\sigma^2} \right), \quad (2)$$

где X_i – вектор дескрипторов неизвестного образца по i -му ПИП; λ_{ω_ℓ} – число

образцов-примеров в датасет i -го ПИП, отнесенных экспертами к кластеру ω_ℓ ; $\lambda_{\omega_\ell}^-$ – число образцов-примеров в датасет i -го ПИП, отнесенных экспертами к кластерам $\bar{\omega}_\ell$; $X_{i\omega_\ell}^j$ – j -й пример из кластера ω_ℓ из i -го ПИП; $X_{i\bar{\omega}_\ell}^j$ – j -й пример из кластера $\bar{\omega}_\ell$ из i -го ПИП; σ – настраиваемый параметр, который в общем случае будет различен для различных кластеров.

Представленная на рисунке 1 структура выделяет только один кластер степени тяжести ВБП. Если необходимо определить вероятности нахождения

пациента в L кластерах ВБП, то, соответственно, необходимо использовать L раз формулы (1) и (2).

Двухканальная агрегация L пар выходов PNN-FNN происходит с помощью еще одного макрослоя – FNN_ℓ^* (рис. 2). Макрослой FNN^* состоит из L модулей FNN с одинаковой структурой. Каждый блок этого макрослоя состоит из двух нейронных слоев. В этом же макрослое учитывается влияние коморбидности на степень тяжести ВБП. Этот слой является моделью экспертной оценки результатов, получаемых в макрослоях PNN-FNN.




Рис. 2. Структура гибридной нейронной сети PNN-FNN-FNN*

Fig. 2. Structure of the hybrid neural network PNN-FNN-FNN*

Первый слой содержит два нейрона. В первом осуществляется вычисление уверенности нахождения патологии в кластере степени тяжести ВБП ω_ℓ , а во втором – уверенность ее нахождения в других кластерах $\bar{\omega}_\ell$. Схема соединения выходов структуры PNN-FNN и входов макрослоя FNN* построена таким образом, чтобы нечеткая операция, которая осуществляется в нейронах первого слоя, была аналогична операции алгебраического сложения вероятностей, поэтому на нейроны первого слоя модулей макрослоя FNN* поступают свидетельства, подтверждающие одно и то же событие: на первый нейрон поступает информация, подтверждающая нахождение пациента в кластере ω_ℓ , а на второй – информация, подтверждающая его нахождение вне этого кластера $\bar{\omega}_\ell$.

Второй слой модуля макрослоя FNN* агрегирует нечеткую информацию предшествующего слоя и содержит один нейрон. Алгоритм операции, которая в нем реализуется, представлен на рисунке 3. Входными параметрами алгоритма являются операнды a , b , c и d . Операнды a и b – это выходы соответствующих нейронов первого слоя соответствующего модуля макрослоя FNN*. Эти операнды агрегируются в блоке 2 в соответствии с формулой [17]

$$Cmb(a,b) = \frac{a-b}{1-\min(a,b)}, \quad (3)$$

где a – уверенность нахождения патологии в кластере ω_ℓ ; b – уверенность нахождения патологии в кластерах $\bar{\omega}_\ell$.

В блоке 3 выполняется сравнение величины Cmb с пороговым значением c :

ЕСЛИ $Cmb \leq c$ ТО $K_{\omega_\ell} = 0$ (блок 5),

ИНАЧЕ «выполняем блок 4», (4)

где K_{ω_ℓ} – уверенность нахождения патологии в кластере степени тяжести ω_ℓ .

Если результат вычисления Cmb превысил порог c , то в блоке 4 вычисляется коэффициент уверенности нахождения пациента в кластере ω_ℓ . В этом же блоке учитывается влияние коморбидности на степень тяжести ВБП посредством операции tms :

$$tms = Cmb \cdot d. \quad (5)$$

С этой целью для каждого коморбидного заболевания строится логистическая модель:

$$R_{\omega_\ell}(k) = \frac{\exp(t)}{1 + \exp(t)}, \quad (6)$$

где $t = \beta_0 + \beta_1 y_1 + \beta_2 y_2 + \dots + \beta_n y_n$; $y_1, \dots, y_i, \dots, y_n$ – факторы риска коморбидной патологии ω_ℓ ; $\beta_0, \beta_1, \dots, \beta_i, \dots, \beta_n$ – параметры модели, определяемые при обучении; k – номер контрольной точки, в которой определен медицинский риск (МР) ИБС по факторам риска (ФР), представленным диаграммой (рис. 4).




Рис. 3. Схема алгоритма нечеткой операции во втором слое блоков макрослоя FNN*

Fig. 3. Scheme of the fuzzy operation algorithm in the second layer of blocks of the FNN* macrolayer




Рис. 4. Диаграмма значимости факторов риска ишемической болезни сердца

Fig. 4. Diagram of the significance of risk factors for coronary heart disease

В общем случае операнд d является вектором, число компонент которого определяется числом кластеров степени тяжести ВБП. В принципе этих компонент может быть меньше. В частном случае d вырождается в скаляр, и на все модули макрослоя FNN* подается одинаковое число, учитывающее влияние коморбидности на кластер степени тяжести ВБП.

Таким образом, в слой FNN* интегрируется база моделей коморбидных заболеваний. Учитывая, что коморбидное заболевание известно априори, ЛПР имеет возможность подключить к слою FNN* соответствующую модель коморбидного заболевания, которая формирует МР по данному заболеванию. На выходе модели только один выход, а не L , как показано на рисунке 2. Однако здесь необходимо учесть следующие обстоятельства. Выход текущей модели коморбидности может только увеличить

риск ВБП, поэтому его значение подается на выходной нейрон модуля макрослоя слоя FNN*. Это значение необходимо «взвесить» по степени МР основного заболевания, т. е. ВБП. Весовые коэффициенты $w_1, w_2, \dots, w_L$ при этом определяются либо при обучении гибридной НС, либо задаются экспертами. Таким образом, выходной слой модулей макрослоя FNN* может быть реализован как посредством обучаемой НС, так и используя нечеткую НС, согласно алгоритму рисунка 3 и формулы (2).

Система поддержки принятия врачебных решений при мониторинге пациентов, больных внебольничной пневмонией

Для формализации решения по госпитализации больного ВБП используют ряд шкал оценки степени тяжести ВБП [18; 19]. Эти шкалы имеют ряд недостатков, обусловленных специфической особенностью больной оценки, а также

неоднозначностью в релевантности некоторых ФР (например, «возраст»).

В связи с вышеизложенным выдвигается ряд требований, которым должна удовлетворять система поддержки принятия врачебных решений (СППВР) мониторинга степени тяжести ВБП:

- ФР ВБП должны быть сгруппированы по блокам таким образом, чтобы отсутствие некоторых ФР в том или ином блоке или полное отключение блока ФР не приводило к некорректной работе СППВР;

- в СППВР должна быть предусмотрена возможность как получения «сырых» данных из базы пациентов поликлиники, так и путем оперативной передачи данных о состоянии здоровья пациента самим пациентом или автоматически без его участия;

- в СППВР должен быть включен модуль контроля степени тяжести ВБП, основанный на одной из рабочих шкал риска ВБП или на нескольких шкалах, с комбинацией ФР или возможности выбора одной из рабочих шкал степени тяжести ВБП;

- в СППВР необходимо включить базу классификаторов степени тяжести коморбидных заболеваний с возможностью выбора ЛПР конкретного классификатора риска коморбидного заболевания;

- в СППВР необходимо включить модуль контроля эффективности лечения ВБП;

- учитывая, что для врача важен дифференциальный диагноз между вирусной инфекцией ВБП и бактериальной ВБП, так как ошибка приводит к необоснованному назначению антимикробных препаратов, в СППВР должен присутствовать модуль дифференциальной диагностики вирусной ВБП и бактериальной ВБП.

Структурная схема СППВР, предназначенной для оценки степени тяжести ВБП мониторинга эффективности лекарственных назначений и удовлетворяющая этим требованиям, представлена ниже (рис. 5).

В ее состав входят три решающих модуля. В первом модуле определяется степень тяжести ВБП, показатель которой учитывается врачом при принятии решения о госпитализации пациента. Во втором модуле оценивается изменение степени тяжести ВБП в процессе лечения и при необходимости вносятся коррективы в план лечения ВБП, эффективность плана лечения ВБП. Третий модуль предназначен для поддержки принятия решений при дифференциальной диагностики ВБП.

Модуль контроля степени тяжести ВБП работает совместно с модулем оценки риска коморбидного заболевания. ЛПР при необходимости может подключить этот модуль к модулю оценки степени тяжести ВБП, предварительно выбрав из базы классификаторов МР коморбидных заболеваний соответствующий классификатор МР.




Рис. 5. Структурная схема СППВР для мониторинга состояния здоровья пациентов, больных внебольничной пневмонией

Fig. 5. Structural diagram of the MDSS for monitoring the health status of patients with community-acquired pneumonia

Результаты и их обсуждение

Синтез классификатора для оценки риска коморбидного заболевания

Правильный кластер степени тяжести ВБП оперативно установить весьма сложно, что связано с наличием коморбидных заболеваний, которые имеют общие ФР с ВБП, а также оказывают значительное влияние на ее степень тяжести. Поэтому важно оценить влияние коморбидного заболевания на решение вопроса по госпитализации больного, а также контролировать в процессе лечения ВТБ развитие не только основного

заболевания – ВБП, но и коморбидного заболевания – ИБС.

В частности, это относится к ишемической болезни сердца (ИБС). Поэтому в ГНК был включен решающий модуль, позволяющий оценить влияние риска ИБС на риск ВБП. Классификатор риска ИБС – гибридный классификатор (ГК) был построен по методике, предложенной в [4; 20]. В таблице 1 представлен вариант такого набора ФР, а также их градации, которые использовались при построении ГК ишемического риска.

Таблица 1. Информативные признаки риска ишемической болезни сердца

Table 1. Informative signs of risk of coronary heart disease

ФР	Наименование ФР	Подкатегория ФР	Наименование подкатегории ФР
x_1	Возраст	–	–
x_2	Половая принадлежность	0	Ж
		1	М
x_3	Семейное положение	1	Состоит в браке, психологический климат в семье благоприятный
		2	Холост
		3	Состоит в браке, психологический климат в семье неблагоприятный
x_4	Наследственные факторы риска развития ИБС	0	В анамнезе ИБС присутствует
		1	В анамнезе ИБС отсутствует
x_5	Сахарный диабет	0	Нет
		1	Да
x_6	Ожирение	0	Нет
		1	Да
x_7	Гиподинамия	0	Нет
		1	Да
x_8	Курение	0	Нет
		1	Да

Окончание табл. 1 / Table 1 (ending)

ФР	Наименование ФР	Подкатегория ФР	Наименование подкатегории ФР
x_9	Приём алкоголя	0	Нет
		1	Да
x_{10}	Стрессовые ситуации	0	Нет
		1	Да
x_{11}	Уровень содержания холестерина в крови	1	4,5–5ммоль/л
		2	>5ммоль/л
x_{12}	Уровень артериального давления	1	Соответствует возрастной норме
		2	Выше нормы
		3	Ниже нормы
x_{13}	Сократительная функция миокарда	0	Не нарушена
		1	Нарушена
x_{14}	Общая продолжительность ишемических изменений по ЭКГ	0	Менее года
		1	Больше года
x_{15}	Смещение сегмента ST	0	Ниже оси
		1	Норма
		2	Выше оси
x_{16}	Частота сердечных сокращений	0	Брадикардия
		1	Норма
		2	Тахикардия
x_{17}	Количество аритмических эпизодов за сутки	–	–
x_{18}	Перекисное окисление липидов (ПОЛ)	–	–
x_{19}	Антиокислительная активность (АОА)	–	–

Наибольшую прогностическую ценность при прогнозировании ишемического риска (по Кульбаку) имеют ФР x_{12} , x_{14} , ..., x_{20} . Данные ФР обеспечивают достаточный для формирования практических заключений прогноз. Для повышения точности прогнозирования развития риска ИБС на основе полученных

экспертных заключений в пул ФР введен дополнительный ФР – уровень психоэмоционального напряжения (ПЭН, x_{21}). Уровень ПЭН определяется согласно методике, предложенной в [21].

Для получения шкалы ишемического риска использовалась кривая кумулятивной выживаемости, полученная

по результатам наблюдения экспериментальной группы больных ИБС в течение 24 месяцев. Кумулятивная выживаемость в экспериментальной группе представлена на графике (рис. 6). В качестве контрольной точки сердечно-сосудистого события выбрано событие

«инфаркт миокарда» или «летальный исход». Для выделения кластеров ишемического риска график кумулятивной выживаемости разбит на три диапазона: [0...8 месяцев], [8 месяцев... 24 месяца] и [>24 месяцев].




Рис. 6. Кумулятивная выживаемость в экспериментальной группе постинфарктных больных

Fig. 6. Cumulative survival in the experimental group of post-infarction patients

На рисунке 7 представлено распределение этих кластеров в двумерном пространстве информативных признаков в программном пакете *GuiGraf* [9; 22]. В качестве информативных признаков использовался индекс Gensini и баллы, полученные на шкале GRACE [1; 2] (C1 – высокий риск, C2 – низкий риск, C3 – средний риск). ГК риска ИБС синтезируется лицом, принимающим решения (ЛПР), с помощью специализированных программных средств. На

рисунке 8 представлена структурная схема ГК риска ИБС, построенного в соответствии набором ФР ИБС (табл. 1) и ПЭН. Пространство ФР $x_1 \dots x_{11}$ и $x_{12} \dots x_{18}$ было разделено на сегменты, в каждом из которых определялся коэффициент уверенности риска ИБС по данному сегменту ФР – КУ. В классификаторах, определяющих КУ1 и КУ2, были использованы виртуальные потоки (ВП) [23; 24; 25; 26].




Рис. 7. Графический интерфейс модуля GuiGraf для отображения кластеров адаптационного потенциала, полученных по графику кумулятивной выживаемости в пространстве двух маркеров кардиологического риска

Fig. 7. Graphical interface of the GuiGraf module for displaying clusters of adaptive potential obtained from the cumulative survival graph in the space of two cardiac risk markers




Рис. 8. Модель гибридного классификатора риска ишемической болезни сердца с виртуальными потоками

Fig. 8. Model of a hybrid risk classifier for coronary heart disease with virtual flows

Особенность ГК с ВП (рис. 9) заключается в том, что на входы НС поступают две группы ФР: ФР, подтверждающие текущую гипотезу (X_i), и ФР, которые опровергают текущую гипотезу ($\overline{X}_i$) [26]. Все эти ФР анализируются в классификаторе NET, на выходе которого имеем уверенность в текущей гипотезе (медицинский риск R_m). Коэффициент уверенности в медицинском риске

KU_m определяется на основе нечеткого логического вывода или построения математической модели и используется в качестве ВП на одном из входов классификатора NET. Его вес определяется в результате настройки нейронной сети NET (рис. 10). Отсутствие некоторых ФР не повлечет за собой нарушение работы НС, так как при возникновении такой ситуации, полагаем, $X_i = \overline{X}_i = 0$.




Рис. 9. Гибридный классификатор с виртуальным потоком

Fig. 9. Hybrid classifier with virtual stream

Коэффициент КУЗ (рис. 9) определяется с помощью «слабого» классификатора, полученного из ФР x_{18} и x_{19} (табл. 1). Дескрипторы по этим ФР определялись по следующим формулам:

$$\delta x_{\Pi} = \frac{x_{\Pi}^H - x_{\Pi}^T}{x_{\Pi}^H} 100\%, \quad (7)$$

$$\delta x_A = \frac{x_A^H - x_A^T}{x_A^H} 100\%, \quad (8)$$

где x_{Π}^H и x_A^H – ПОЛ и АОА в норме; $x_{\Pi}^T = x_{19}$ и $x_A^T = x_{20}$ – ПОЛ и АОА, соответственно, у обследуемого пациента.

На четвертый вход NET (рис. 9) поступает КУ4, отражающий риск ИБС по ПЭН пациента. Этот предиктор формируется из трех блоков признаков, описанных в [21]. Из четырех частных коэффициентов уверенности в риске ИБС формировался вектор {КУ1 ... КУ4}, по которому получали математическую модель ВП и который поступал на пятый вход нейронной сети NET [23; 24; 25]. В результате был сформирован пятикомпонентный вектор дескрипторов для нейронной сети NET, которая имеет три выхода, соответствующие классам «Низкий риск», «Средний риск» и «Высокий риск».

Оценка показателей качества классификации риска ИБС осуществлялась посредством ROC-анализа. Предвари-

тельно устанавливалось пороговое КУ_{Пор} значение решающего правила, и путем варьирования этого параметра изменялись соотношения между диагностической чувствительностью (ДЧ) и диагностической специфичностью (ДС) классификаторов ишемического риска. ROC-анализ осуществлялся при разделении двух классов – класс ω_1 и класс ω_0 ($\{\omega_2 \cup \omega_3\}$). В этом случае на выходе ГК имеем КУ _{ω_1} , и решение о принадлежности объекта к классу ω_1 принимается посредством решающего правила продукционного типа:

ЕСЛИ КУ _{ω_1} > КУ_{Пор} ТО ω_1 ИНАЧЕ ω_0 . (9)

Для получения ROC-кривой задавался шаг изменения КУ_{Пор}, а его динамический диапазон выбирался с учетом особенностей аппроксимации гистограмм H_{ω_0} и H_{ω_1} (рис. 10).

В таблице 2 приведены результаты ROC-анализа для построенного ГК.




Рис. 10. Гистограммы распределения классов ω_0 и ω_1 по величине КУ _{ω_1}

Fig. 10. Histograms of the distribution of classes ω_0 and ω_1 by the value of CF _{ω_1}

Таблица 2. Результаты ROC-анализа для гибридного классификатора ишемического риска первого и нулевого классов**Table 2.** Results of ROC analysis for a hybrid classifier of ischemic risk of the first and zero classes

КУ _{Пор}	0,50	0,55	0,60	0,65	0,70	0,75	0,80
ДЧ	0,85	0,80	0,70	0,60	0,50	0,45	0,2
ДС	0,80	0,85	0,90	0,92	0,95	0,97	1

Показатели качества для предложенной модели ГК, полученные на контрольной выборке, и логистической

модели, которая была выбрана в качестве прототипа, полученные на той же самой выборке, приведены ниже (табл. 3).

Таблица 3. Экспериментальные данные по прогнозированию риска ИБС на контрольной выборке гибридным классификатором и классификатором-прототипом**Table 3.** Experimental data on predicting the risk of coronary artery disease on a control sample using a hybrid classifier and a prototype classifier

Обследуемые	Модель гибридного классификатора, %			Логистическая модель (10), %		
$n_{\omega_1} = 100$	90	94	88	75	79	77
$n_{\omega_2} = 60$	85	86		74	75	
$n_{\omega_3} = 30$	87	96		75	78	

В качестве прототипа для ГК ишемического риска была выбрана логистическая регрессионная модель [20]:

$$P = \frac{1}{1 + \exp(-z)}, \quad (10)$$

где параметр z определялся посредством уравнения регрессии

$$z = -4,29 + 1,37 \cdot Y_1 + 1,66 \cdot Y_2 + 3,36 \cdot Y_3, \quad (11)$$

где $Y_1 = 1$, если фракции выброса левого желудочка (ФВ ЛЖ) < 50 ; $Y_1 = 0$, если ФВ ЛЖ ≥ 50 ; $Y_2 = 1$, если анемия присутствует; $Y_2 = 0$, если анемия отсутствует; $Y_3 = 1$, если индекс Gensini ≥ 48 баллов; $Y_3 = 0$, если индекс Gensini < 48 баллов [20].

В ходе сравнительного анализа полученных данных было установлено, что

оценки, полученные в ходе работы предложенного ГК, в удовлетворительной степени соответствуют экспертным оценкам.

Экспериментальные исследования гибридного нейронечеткого классификатора степени тяжести внебольничной пневмонии при наличии коморбидности

В исследование было включено 80 пациентов, больных ВБП, с коморбидностью в виде ИБС. В таблице 4 представлены гендерные, возрастные и медицинские характеристики этих пациентов. Из этих пациентов были сформированы две экспериментальные группы: $n_{\omega_0} = 46$ без риска ИБС и $n_{\omega_1} = 34$

пациентов с коморбидным заболеванием ВБП + ИБС. Использовалась двухальтернативная классификация посредством

объединения пациентов со средней и тяжелой формами ВБТ в один класс (ω_0).

Таблица 4. Характеристики пациентов в экспериментальной группе

Table 4. Characteristics of patients in the experimental group

Показатели	Нетяжелая	Средняя	Тяжелая
1. Количество больных ВБП, абс., %	128 (64)	100 (33)	72 (36)
2. Количество больных с коморбидным (ИБС), заболеванием абс., %	34 (26,5)	28 (38)	18 (25)
3. Возраст, лет. Ме [Q25–Q75]	52 [36–68]	58 [38–72]	55 [41–76]
4. Доля мужчин, %	55	60	62
5. Доля женщин, %	45	40	38

В таблице 5 представлены экспериментальные данные по оценке степени тяжести ВБП в экспериментальной группе ВБП + ИБС на обучающей выборке классификатором, учитывающим риск коморбидного заболевания, и

классификатором без учета коморбидности NFN.

В таблице 6 приведены показатели качества разработанных классификаторов на обучающей выборке (ВБП + ИБС), вычисленные по данным таблицы 5.

Таблица 5. Экспериментальные данные по оценке степени тяжести ВБП в экспериментальной группе ВБП + ИБС на обучающей выборке

Table 5. Experimental data on assessing the severity of CAP in the experimental group CAP + CHD on the training set

Обследуемые	Гибридный нейронечеткий классификатор		Классификатор NFN	
	ω_0 (тяжелая)	ω_1 (легкая)	ω_0 (тяжелая)	ω_1 (легкая)
$n_{\omega_0} = 46$	38	8	30	16
$n_{\omega_1} = 34$	4	30	6	28

Таблица 6. Показатели качества классификаторов степени тяжести пневмонии на обучающей выборке

Table 6. Quality indicators of pneumonia severity classifiers on the training set

Обследуемые	Гибридный нейронечеткий классификатор, %			Классификатор NFN, %		
	ДЧ	ДС	ДЭ	ДЧ	ДС	ДЭ
$n_{\omega_0} = 46$	82	88	85	65	82	73
$n_{\omega_1} = 34$	88	82		82	65	

Контрольная группа формировалась путем случайного выбора по 25 пациентов из каждой из вышесформированных экспериментальных групп. В таблице 7 представлены результаты диагностики контрольной выборки коморбидных

пациентов (ВБП + ИБС) двумя разработанными классификаторами.

В таблице 8 приведены показатели качества гибридных классификаторов в контрольной группе (ВБП + ИБС), вычисленные по данным таблицы 7.

Таблица 7. Экспериментальные данные по оценке степени тяжести ВБП в экспериментальной группе ВБП + ИБС на контрольной выборке

Table 7. Experimental data on assessing the severity of CAP in the experimental group CAP + CHD in the control sample

Обследуемые	Гибридный нейросетевой классификатор		Классификатор NFN	
	ω_0 (тяжелая)	ω_1 (легкая)	ω_0 (тяжелая)	ω_1 (легкая)
$n_{\omega_0} = 25$	21	4	18	7
$n_{\omega_1} = 25$	3	22	6	19

Таблица 8. Экспериментальные данные по классификации степени тяжести пневмонии на контрольной выборке различными моделями классификаторов

Table 8. Experimental data on classification of the severity of pneumonia on a control sample using various classifier models

Обследуемые	Гибридный нейросетевой классификатор, %			Классификатор NFN, %		
	ДЧ	ДС	ДЭ	ДЧ	ДС	ДЭ
$n_{\omega_0} = 25$	84	88	86	72	76	74
$n_{\omega_1} = 25$	88	84		76	72	

Таким образом, учет риска коморбидного заболевания на примере ИБС при определении степени тяжести ВБП позволил повысить показатели качества классификации более чем на 10% по всем показателям качества классификации степени тяжести пневмонии.

Выводы

1. При учете влияния коморбидных заболеваний на степень тяжести внебольничной пневмонии целесообразно определять как риск самого

коморбидного заболевания, так и степень тяжести (кластер) внебольничной пневмонии. Эта процедура может быть реализована посредством гибридного нейронечеткого классификатора, в основе которого положена гибридная нейронечеткая сеть, содержащая три макрослоя, построенных на парадигме вероятностных нейронных сетей и на парадигме нечеткого логического вывода.

2. Сформированы технические требования для системы поддержки принятия врачебных решений по оценки

степени тяжести внебольничной пневмонии. Согласно этим требованиям разработана структура системы поддержки принятия врачебных решений, предназначенная для мониторинга степени тяжести внебольничной пневмонии и оценки эффективности ее лечения. В систему интегрированы три решающих модуля, позволяющие осуществлять контроль степени тяжести внебольничной пневмонии с учетом коморбидности, контроль эффективности плана лечения и модуль дифференциальной диагностики, позволяющий определять этиологию заболевания.

3. Для классификации риска ИБС у больных внебольничной пневмонией предложен гибридный классификатор с иерархической структурой, на нижнем иерархическом уровне которого включены четыре «слабых» классификатора, построенные на основе нечеткого логического вывода. На верхнем иерархическом уровне гибридного классификатора включена полносвязная нейронная сеть с дополнительным входом, полученным посредством модели виртуаль-

ного потока. Апробация гибридного классификатора риска ИБС позволяет рекомендовать его использовать в гибридном нейронечетком классификаторе для определения степени тяжести внебольничной пневмонии у коморбидных больных с сердечно-сосудистыми заболеваниями.

4. Осуществлена сравнительная оценка показателей качества классификации степени тяжести пневмонии двух моделей разработанного гибридного нейронечеткого классификатора: с гибридным классификатором ишемического риска и без гибридного классификатора ишемического риска, с известной регрессионной моделью степени тяжести внебольничной пневмонии. Эксперименты показали, что включение в гибридный нейронечеткий классификатор степени тяжести внебольничной пневмонии гибридного классификатора ишемического риска позволяет повысить качество оценки степени тяжести внебольничной пневмонии более чем на 10% по всем показателям качества.

Список литературы

1. Внебольничная пневмония у взрослых: практические рекомендации по диагностике, лечению и профилактике (пособие для врачей) / А. Г. Чучалин, А. И. Синопальников, Р. С. Козлов [и др.] // Клиническая микробиология и антимикробная химиотерапия. 2010. Т. 12, № 3. С. 186–225.
2. Клинические рекомендации по диагностике, лечению и профилактике тяжелой внебольничной пневмонии у взрослых / А. Г. Чучалин, А. И. Синопальников, Р. С. Козлов [и др.] // Пульмонология. 2014. № 4. С. 13–48. <https://doi.org/10.18093/0869-0189-2014-0-4>.
3. Создание прогностической модели для оценки степени тяжести внебольничной пневмонии / Ю. А. Рогожкина, Т. А. Мищенко, Л. М. Малишевский [и др.] // Бюллетень

физиологии и патологии дыхания. 2019. Т. 1, № 71. С. 45–50. https://doi.org/10.12737/article_5c898b1674b5d2.31350435.

4. Сиротко И. И., Самойлов Р. Г. Математические модели внебольничной пневмонии // Сибирский медицинский журнал. 2007. № 2. С. 5–10.

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

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

7. 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. Т. 4, № 40. С. 61–73.

8. Способ моделирования нечетких моделей в пакете MATLAB для биомедицинских приложений / В. В. Жилин, С. А. Филист, Р. С. Халед Абдул, О. В. Шаталова // Медицинская техника. 2008. № 2. С. 15–18.

9. Жилин В. В., Филист С. А., Аль-Муаалеми В. А. Гибридный способ классификации биосигналов на основе технологий нечеткой логики принятия решений и нейронных сетей // Биомедицинская радиоэлектроника. 2009. № 5. С. 77–82.

10. Интеллектуальные информационные системы для мониторинга эффективности лекарственных назначений и терапевтических процедур / С. А. Филист, Т. В. Петрова, К. В. Подмастерьев, О. В. Шаталова // Нейрокомпьютеры и их применение: тезисы докладов XVI Всероссийской научной конференции (13 марта 2018 г.). М.: Московский государственный психолого-педагогический университет, 2018. С. 74–77.

11. Нейросетевые модели для метаанализа медико-экологических данных / А. Г. Курочкин, В. В. Протасова, С. А. Филист [и др.] // Нейрокомпьютеры: разработка, применение. 2015. № 6. С. 48–53.

12. Алгоритмы мониторинга эффективности терапевтических и реабилитационных процедур по показателям клинического анализа крови в системе поддержки принятия врачебных решений / А. В. Бутусов, А. В. Киселев, Е. В. Петрунина, Р. И. Сафронов, В. В. Песок, А. Е. Пшеничный // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 1. С. 170–190. <https://doi.org/10.21869/2223-1536-2023-13-1-170-190>.

13. Филист С. А., Шаталова О. В., Ефремов М. А. Гибридная нейронная сеть с макрослоями для медицинских приложений // Нейрокомпьютеры: разработка, применение. 2014. № 6. С. 35–39.
14. 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. Т. 2, № 23. С. 77–82.
15. Филист С. А., Шуткин А. Н., Уварова В. В. Структурно-функциональная модель метаанализа медико-экологических данных // Актуальные направления научных исследований XXI века: теория и практика. 2015. Т. 3, № 8-1 (19-1). С. 364–367. <https://doi.org/10.12737/15449>.
16. Программное обеспечение интеллектуальной системы классификации форменных элементов крови / Р. А. Томакова, С. А. Филист, В. В. Жилин [и др.] // Фундаментальные исследования. 2013. № 10, ч. 2. С. 303–307.
17. Моросанова Н. А., Соловьев С. Ю. Формальные свойства схемы Шортлиффа // Управление большими системами. 2012. № 36. С. 5–38.
18. Mobile Health Devices as Tools for Worldwide Cardiovascular Risk Reduction and Disease Management / J. D. Piette, J. List, G. K. Rana [et al.] // Circulation. 2015. Vol. 132, N 21. P. 2012–2027. <https://doi.org/10.1161/CIRCULATIONAHA.114.008723>.
19. Фисенко О. В., Синопальников А. И. Тяжелая внебольничная пневмония и шкалы оценки прогноза // Практическая пульмонология. 2014. № 2. С. 20–26.
20. Возможности прогнозирования повторного инфаркта миокарда у больных трудоспособного возраста / Е. А. Шишкина, О. В. Хлынова, А. В. Туев [и др.] // Российский кардиологический журнал. 2020. Т. 25, № 8. С. 69–74. <https://doi.org/10.15829/1560-4071-2020-3909>.
21. Комплексная оценка уровня психоэмоционального напряжения / Н. А. Кореневский, О. И. Филатова, М. И. Лукашов, Р. А. Крупчатников // Биомедицинская радиоэлектроника. 2009. № 5. С. 4–9.
22. Ермаков С. А., Болгов А. А. Оценка риска с использованием нейро-нечеткой системы // Информация и безопасность. 2022. Т. 25, № 4. С. 583–592. <https://doi.org/10.36622/VSTU.2022.25.4.012>.
23. Виртуальные потоки в гибридных решающих модулях классификации сложноструктурируемых данных / А. В. Киселев, Д. Ю. Савинов, С. А. Филист, О. В. Шаталова, В. В. Жилин // Прикаспийский журнал: управление и высокие технологии. 2018. Т. 2, № 42. С. 137–149.
24. 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.

25. Нейросетевые модули с виртуальными потоками для классификации и прогнозирования функционального состояния сложных систем / А. В. Киселев, Т. В. Петрова, С. В. Дегтярев, А. Ф. Рыбочкин, С. А. Филист, О. В. Шаталова, В. Н. Мишустин // Известия Юго-Западного государственного университета. 2018. Т. 22, № 4(79). С. 123–134. <https://doi.org/10.21869/2223-1560-2018-22-4-123-134>.

26. Слабые классификаторы с виртуальными потоками в интеллектуальных системах прогнозирования сердечно-сосудистых осложнений / А. В. Киселев, М. В. Томаков, Е. В. Петрунина [и др.] // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9, № 1(30). С. 6–19.

References

1. Chuchalin A. G., Sinopal'nikov A. I., Kozlov R. S., eds. Vnebol'nichnaya pnevmoniya u vzroslyh: prakticheskie rekomendatsii po diagnostike, lecheniyu i profilaktike (Posobie dlya vrachej) [Community-acquired pneumonia in adults: practical recommendations for diagnosis, treatment and prevention (A manual for doctors)]. *Klinicheskaya mikrobiologiya i antimikrobnaya himioterapiya = Clinical Microbiology and Antimicrobial Chemotherapy*, 2010, vol. 12, no. 3, pp. 186–225.

2. Chuchalin A. G., Sinopal'nikov A. I., Kozlov R. S., eds. Klinicheskie rekomendatsii po diagnostike, lecheniyu i profilaktike tyazhelej vnebol'nichnoj pnevmonii u vzroslyh [Clinical guidelines on diagnosis, treatment and prevention of severe community-acquired pneumonia in adults]. *Pul'monologiya = Pulmonology*, 2014, no. 4, pp. 13–48. <https://doi.org/10.18093/0869-0189-2014-0-4>

3. Rogozhkina Yu. A., Mishchenko T. A., Malishevskij L. M., eds. Sozdanie prognosticheskoy modeli dlya otsenki stepeni tyazhesti vnebol'nichnoj pnevmonii [The creation of predictive models for assessing the severity of community-acquired pneumonia]. *Byulleten' fiziologii i patologii dyhaniya = Bulletin of Physiology and Pathology of Respiration*, 2019, vol. 1, no. 71, pp. 45–50. https://doi.org/10.12737/article_5c898b1674b5d2.31350435

4. Sirotko I. I., Samojlov R. G. Matematicheskie modeli vnebol'nichnoj pnevmonii [Mathematical models of predicting course of community-acquired pneumonia in young persons]. *Sibirskij meditsinskij zhurnal = Siberian Medical Journal*, 2007, no. 2, pp. 5–10.

5. Kurochkin A. G., Zhilin V. V., Filist S. A., Surzhikova S. A. Ispol'zovanie gibridnyh nejrosetevykh modelej dlya mnogoagentnykh sistem klassifikatsii v geterogennom prostranstve informativnykh priznakov [Use of hybrid neural network models for multi-agent classification systems in heterogeneous space of informative signs]. *Prikaspijskij zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies*, 2015, vol. 3, no. 31, pp. 85–95.

6. Kurochkin A. G., Protasova V. V., Filist S. A., Shutkin A. N. Nejrosetevye modeli dlya metaanaliza mediko-ekologicheskikh dannyh [Neural network models for metaanalysis of medical and environmental data]. *Nejrokomp'yutery. Razrabotka, primenenie = Neurocomputers. Development, Application*, 2015, no. 6, pp. 42–48.

7. Petrova T. V., Kuz'min A. A., Savinov D. Yu., Serebrovskij V. V. Raspredelemnnye avtonomnye intellektual'nye agenty dlya monitoringa i meta-analiza effektivnosti upravleniya zhivymi sistemami [Distributed autonomous intellectual agents for monitoring and metaanalysis of living systems management effectiveness]. *Prikaspijskij zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Control and High Technologies*, 2017, vol. 4, no. 40, pp. 61–73.

8. Zhilin V. V., Filist S. A., Haled Abdul R. S., Shatalova O. V. Sposob modelirovaniya nechetkih modelej v pakete MATLAB dlya biomeditsinskih prilozhenij [A method for modeling fuzzy models in the MATLAB package for biomedical applications]. *Medsinskaya tekhnika = Medical Equipment*, 2008, no. 2, pp. 15–18.

9. Zhilin V. V., Filist S. A., Al'-Muaalemi V. A. Gibridnyj sposob klassifikatsii biosignalov na osnove tekhnologij nechetkoj logiki prinyatiya reshenij i nejronnyh setej [Hybrid method of classification of biosignals based on fuzzy decision logic and neural networks technologies]. *Biomeditsinskaya Radioelektronika = Biomedicine Radioengineering*, 2009, no. 5, pp. 77–82.

10. Filist S. A., Petrova T. V., Podmaster'ev K. V., Shatalova O. V. [Intelligent information systems for monitoring the effectiveness of medicinal prescriptions and therapeutic procedures]. *Nejrokomp'yutery i ih primenenie. Tezisy dokladov XVI Vserossijskoj nauchnoj konferentsii (13 marta 2018 g.)* [Neurocomputers and their application: Abstracts of the XVI All-Russian Scientific Conference (March 13, 2018)]. Moscow, Moscow State Psychological and Pedagogical University Publ., 2018, pp. 74–77. (In Russ.)

11. Kurochkin A. G., Protasova V. V., Filist S. A., eds. Nejrosetevye modeli dlya metaanaliza mediko-ekologicheskikh dannyh [Neural network models for meta-analysis of medical and environmental data]. *Nejrokomp'yutery: razrabotka, primenenie = Neurocomputers. Development, Application*, 2015, no. 6, pp. 48–53.

12. Butusov A. V., Kiselev A. V., Petrunina E. V., Safronov R. I., Pesok V. V., Pshenichnyj A. E. Algoritmy monitoringa effektivnosti terapevticheskikh i reabilitatsionnyh protsedur po pokazatelyam klinicheskogo analiza krovi v sisteme podderzhki prinyatiya vrachebnyh reshenij [Algorithms for Monitoring the Effectiveness of Therapeutic and Rehabilitation Procedures Based on Clinical Blood Analysis Indicators in the Medical Decision Support System]. *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, vol. 13, no. 1, pp. 170–190. <https://doi.org/10.21869/2223-1536-2023-13-1-170-190>.

13. Filist S. A., Shatalova O. V., Efremov M. A. Gibrnaya nejronnaya set' s makrosloyami dlya meditsinskih prilozhenij [Hybrid neural network with macro layers for medical applications]. *Nejrokompyutery: razrabotka, primenenie = Neurocomputers. Development, Application*, 2014, no. 6, pp. 35–39.
14. Emel'yanov S. G., Rybochkin A. F., Filist S. A., Haled A. R. Nejrosetevoy reshayushchij modul' dlya issledovaniya zhivyh system [Neural network solving module for the study of living systems]. *Izvestiya Kurskogo gosudarstvennogo tekhnicheskogo universiteta = Proceedings of the Kursk State Technical University*, 2008, vol. 2, no. 23, pp. 77–82.
15. Filist S. A., Shutkin A. N., Uvarova V. V. Strukturno-funktsional'naya model' metaanaliza mediko-ekologicheskikh dannyh [Structural and functional model of meta-analysis of medical and environmental data]. *Aktual'nye napravleniya nauchnyh issledovanij XXI veka: teoriya i praktika = Current Directions of Scientific Research of the XXI Century: Theory and Practice*, 2015, vol. 3, no. 8–1 (19–1), pp. 364–367. <https://doi.org/10.12737/15449>
16. Tomakova R. A., Filist S. A., Zhilin V. V., eds. Programmnoe obespechenie intellektual'noj sistemy klassifikatsii formennyh elementov krovi [Software intellectual system of classification of formed elements of blood]. *Fundamental'nye issledovaniya = Fundamental Research*, 2013, no. 10, pt. 2, pp. 303–307.
17. Morosanov N. A., Solov'ev S. Yu. Formal'nye svoystva skhemy Shortliffa [Formal properties of the Shortlife scheme]. *Upravlenie bol'shimi sistemami = Managing Large Systems*, 2012, no. 36, pp. 5–38.
18. Piette J. D., List J., Rana G. K., eds. Mobile Health Devices as Tools for Worldwide Cardiovascular Risk Reduction and Disease Management. *Circulation*, 2015, vol. 132, no. 21, pp. 2012–2027. <https://doi.org/10.1161/CIRCULATIONAHA.114.008723>
19. Fisenko O. V., Sinopal'nikov A. I. Tyazhelaya vnebol'nichnaya pnevmoniya i shkaly otsenki prognoza [Severe community-acquired pneumonia and prognosis assessment scales]. *Prakticheskaya pul'monologiya = Practical Pulmonology*, 2014, no. 2, pp. 20–26.
20. Shishkina E. A., Hlynova O. V., Tuev A. V., eds. Vozmozhnosti prognozirovaniya povtornogo infarkta miokarda u bol'nyh trudosposobnogo vozrasta [Prediction of recurrent myocardial infarction in working-age patients]. *Rossiiskij kardiologicheskij zhurnal = Russian Journal of Cardiology*, 2020, vol. 25, no. 8, pp. 69–74. <https://doi.org/10.15829/1560-4071-2020-3909>
21. Korenevskij N. A., Filatova O. I., Lukashov M. I., Krupchatnikov R. A. Kompleksnaya otsenka urovnya psihoemotsional'nogo napryazheniya [Comprehensive assessment of the level of psycho-emotional stress]. *Biomeditsinskaya radioelektronika = Biomedicine Radioengineering*, 2009, no. 5, pp. 4–9.
22. Ermakov S. A., Bolgov A. A. Otsenka riska s ispol'zovaniem nejro-nechetkoj sistemy [Risk assessment using a neuro-fuzzy system]. *Informatsiya i bezopasnost' = Information and Security*, 2022, vol. 25, no. 4, pp. 583–592. <https://doi.org/10.36622/VSTU.2022.25.4.012>

23. Kiselev A. V., Savinov D. Yu., Filist S. A., Shatalova O. V., Zhilin V. V. Virtual'nye potoki v gibridnyh reshayushchih modulyah klassifikatsii slozhnostrukturiruemym dannym [Virtual flows in hybrid decision modules of classification of complex-structured data]. *Pri-kaspijskij zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Control and High Technologies*, 2018, vol. 2, no. 42, pp. 137–149.

24. Kiselev A. V., Shatalova O. V., Protasova Z. U., Filist S. A., Stadnichenko N. S. Modeli latentnyh prediktorov v intellektual'nyh sistemah prognozirovaniya sostoyaniya zhivyh sistem [Models of Latent Predictors in Intellectual Systems for Forecasting the 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*, 2020, vol. 10, no. 1, pp. 114–133.

25. Kiselev A. V., Petrova T. V., Degtyarev S. V., Rybochkin A. F., Filist S. A., Shatalova O. V., Mishustin V. N. Nejrosetevye moduli s virtual'nymi potokami dlya klassifikatsii i prognozirovaniya funktsional'nogo sostoyaniya slozhnyh sistem [Hybrid Deciding Modules with Virtual Streams for Classification and Prediction of Functional State of Complex Systems]. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta = Proceedings of the Southwest State University*, 2018, vol. 22, no. 4(79), pp. 123–134. <https://doi.org/10.21869/2223-1560-2018-22-4-123-134>.

26. Kiselev A. V., Tomakov M. V., Petrunina E. V., eds. Slabye klassifikatory s virtual'nymi potokami v intellektual'nyh sistemah prognozirovaniya serdechno-sosudistykh oslozhnenij [The prediction of cardiovascular complications with the help of weak classifiers with virtual streams in intelligent 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*, 2019, vol. 9, no. 1 (30), pp. 6–19.

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, Cand. of Sci. (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

Филист Сергей Алексеевич, доктор технических наук, профессор, профессор кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: SFilist@gmail.com, ORCID: 0000-0003-1358-671X

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

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

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

Бутусов Андрей Владимирович, аспирант кафедры биомедицинской инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: mustang2004@list.ru, ORCID: 0009-0008-5307-7956

Sergey A. Filist, Dr. of Sci. (Engineering), Professor, Professor of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: SFilist@gmail.com, ORCID: 0000-0003-1358-671X

Leonid V. Shulga, Dr. of Sci. (Medical), Professor, Professor of the Department of Occupational Safety and Environment, Southwest State University, Kursk, Russian Federation, 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

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

Andrey V. Butusov, Post-Graduate Student of the Department of Biomedical Engineering, Southwest State University, Kursk, Russian Federation, e-mail: mustang2004@list.ru, ORCID: 0009-0008-5307-7956