

10. Reyzlin V. I. *Chislennye metody optimizatsii* [Numerical optimization methods], Tomsk, Tomsk Polytechnic University Publ. House, 2011. 105 p.
11. Sklyar B. *Tsifrovaya svyaz. Teoreticheskie osnovy i prakticheskoe primeneniye* [Digital communication. Theoretical bases and practical application], Moscow, Williams Publ., 2004. 1104 p.
12. Shevlyakov D. A. Algoritmy optimizatsii parametrov mnogoporogovogo dekodera [The optimization algorithm parameters multithreshold decoder]. *Novye informatsionnye tekhnologii v nauchnykh issledovaniyakh i v obrazovanii : tezisy dokladov XIX Vserossiyskoy nauchno-tekhnicheskoy konferentsii studentov, molodykh uchenykh i spetsialistov* [New Information Technologies in Research and in Education. Proceedings of the XIX All-Russian Scientific and Technical Conference of Students, Young Scientists and Specialists], Ryazan, Ryazan State Radio Engineering University Publ. House, 2014. pp. 115–121.
13. Shevlyakov D. A. *Sovremennye metody korrektsii oshibok dlya tsifrovyykh sistem peredachi dannykh* [Modern methods of error correction for digital data transmission systems]. *Molodezh, obrazovanie, nauka : materialy VIII Rossiyskoy ezhegodnoy nauchno-prakticheskoy konferentsii magistrantov, aspirantov i molodykh uchenykh* [Youth, Education and Science. Proceedings of the VIII Annual Russian Scientific and Practical Conference of Undergraduates, Graduate Students and Young Scientists], Ufa, East Economics and Law Academy of Humanities Publ. House, 2013, pp. 154–158.
14. Arikan E. Systematic polar coding. *IEEE Communications Letters*, August 2011, vol. 15, no. 8, pp. 860–862.
15. Cushon K., Hemati S., Leroux C., Mannon S., Gross W. J. Energy-Efficient LDPC Decoders Using Differential Binary Message Passing. *IEEE Transactions on Signal Processing*, 2014, vol. 62, no. 3, pp. 619–631.
16. Ould-Cheikh-Mouhamedou Y. A simple and efficient method for lowering the error floors of turbo codes that use structured interleavers. *IEEE Communications Letters*, 2012, vol. 16, no. 3, pp. 392–395.

УДК 004.891

ИСПОЛЬЗОВАНИЕ ГИБРИДНЫХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ МНОГОАГЕНТНЫХ СИСТЕМ КЛАССИФИКАЦИИ В ГЕТЕРОГЕННОМ ПРОСТРАНСТВЕ ИНФОРМАТИВНЫХ ПРИЗНАКОВ¹

Статья поступила в редакцию 04.07.2015, в окончательном варианте 10.09.2015.

Курочкин Александр Геннадиевич, коммерческий директор, ООО «НПЦ “Иннотех”», 305040, Российская Федерация, г. Курск, ул. 50 лет Октября, 94, e-mail: ak.kursk@gmail.com

Жилин Валерий Вячеславович, кандидат технических наук, доцент, Курская государственная сельскохозяйственная академия имени профессора И. И. Иванова, 305004, Российская Федерация, г. Курск, ул. К. Маркса, 70, e-mail: shatolg@mail.ru

Суржикова Светлана Евгеньевна, аспирант, Юго-Западный государственный университет, 305004, Российская Федерация, г. Курск, ул. Челюскинцев, 19, e-mail: moi_lanchik@mail.ru

Филист Сергей Алексеевич, доктор технических наук, профессор, Юго-Западный государственный университет, 305004, Российская Федерация, г. Курск, ул. Челюскинцев, 19, e-mail: SFilist@gmail.com

Для мониторинга функционального состояния органов и систем человека предложено использовать анализ вольтамперных характеристик в биоактивных точках (БАТ) с последующим построением многоагентных классификаторов. С целью получения вектора информативных признаков,

¹ Исследования выполнены при поддержке федеральной целевой программы «Исследования и разработки по приоритетным направлениям развития научно-технологического комплекса на 2014–2020 годы». Проект «Разработка математического и программного обеспечения автоматизированных диагностических комплексов для анализа и классификации изображений мазков периферической крови в процессе лекарственного воздействия».

характеризующего состояние БАТ, использовалась аппроксимация вольтамперной характеристики полиномом седьмого порядка. Для классификации функционального состояния биообъекта применялись многоагентные классификаторы, основанные на вероятностных нейронных сетях и нечетких нейронных сетях. Классификаторы содержат три макрослоя, первый из которых состоит из модулей вероятностных трехслойных нейронных сетей, второй и третий – из модулей двухслойных нечетких нейронных сетей. Количество модулей в этих макрослоях равно числу классов функционального состояния исследуемых систем. Классификаторы позволяют определить субъективные вероятности принадлежности входного вектора (множества векторов в случае гетерогенного пространства информативных признаков) к выделяемым классам состояний исследуемых объектов.

Ключевые слова: вольтамперные характеристики биоматериалов, гетерогенное пространство информативных признаков, классификация состояний, многоагентные классификаторы, алгоритмы анализа, вероятностные нейронные сети, нечеткие нейронные сети

USE OF HYBRID NEURAL NETWORK MODELS FOR MNOGOAGENTNY SYSTEMS OF CLASSIFICATION IN HETEROGENEOUS SPACE OF INFORMATIVE SIGNS

Kurochkin Aleksandr G., commercial director, LLC «RPC" Innotech"», 94 50 let Oktyabrya St., Kursk, 305040, Russian Federation, e-mail: ak.kursk@gmail.com

Zhilin Valeriy V., Ph.D. (Engineering), Associate Professor, Kursk State Agricultural Academy named after Professor I. I. Ivanov, 70 Karl Marks St., Kursk, 305004, Russian Federation, e-mail: shatolg@mail.ru

Surzhikova Svetlana Ye., post-graduate student, South-West State University, 19 Chelyuskintsi St., Kursk, 305004, Russian Federation, e-mail: moi_lanchik@mail.ru

Filist Sergey A., D.Sc. (Engineering), Professor, South-West State University, 19 Chelyuskintsi St., Kursk, 305004, Russian Federation, e-mail: SFilist@gmail.com

To monitor the functional state of organs and systems of the person proposed to use the analysis of current-voltage characteristics of bio-active points, and then build multi-agent classifiers. To obtain the vector of informative features characterizing the state of current-voltage characteristics of bio-active points was used approximation of current-voltage characteristics of a polynomial of the seventh order. In order to diagnose the functional state of a biological object used multi-agent classifiers based on probabilistic neural networks and fuzzy neural networks. Classifiers contain three microslots, the first of which consists of modules of three-layer probabilistic neural networks, the second and the third module of two-layer fuzzy neural networks. The number of modules in these microslots equal to the number of classes of the functional state of the systems studied. Classifiers allow us to determine the subjective probabilities of belonging of the input vector (array of vectors in the case of heterogeneous space of informative features) to be allocated to the classes of States of the studied objects.

Keywords: current-voltage characteristics of biomaterials, heterogeneous space of informative features, classification of States, multi-agent classifiers, analysis algorithms, probabilistic neural network, fuzzy neural network

Введение. Использование биоактивных точек (БАТ) на теле человека для целей диагностики и управления его состоянием традиционно является предметом повышенного интереса в сфере медицины и особенно так называемой «восточной медицины» [5]. Развитие информационных технологий дает дополнительные возможности в этом отношении. Однако эти возможности в существующих публикациях исследованы недостаточно полно. Поэтому целью настоящей статьи является разработка методов и средств компьютерного анализа вольтамперных характеристик (ВАХ) БАТ с применением современных математических методов и аппаратно-программных решений.

Общая характеристика проблематики работы. Биоимпедансные исследования аномальных зон электропроводности – БАТ являются одним из направлений применения информационных технологий для прогнозирования и ранней диагностики социально значимых заболеваний [1]. Однако при этом имеет место большой разброс результатов измерений, обусловленный индивидуальными особенностями организмов, не связанных с патологией. Кроме того, отметим, что такой подход в целом ориентирован не на диагностику патологий отдельных органов и систем организма, а на выявление патологии меридиана.

Эти факторы приводят к тому, что использование биоимпедансного подхода применительно к БАТ вступает в противоречие с традиционной методологией диагностики и лечения, принятой в европейской классической медицине; не позволяет широко применять указанный подход в клинической практике. Поэтому при диагностических исследованиях целесообразно использовать гетерогенное пространство информативных признаков (ИП). Данное пространство представляет собой множество векторов ИП, минимально коррелированных друг с другом. В качестве классификатора в таком признаковом пространстве разумно применять решающий модуль, построенный по блочному (многоагентному) принципу. При этом каждый блок (автономный агент) осуществляет анализ соответствующего вектора ИП и принимает на основе такого анализа автономное решение.

Такой подход предусматривает получение с каждой анализируемой БАТ вектора ИП и достижение многоагентности за счет включения в диагностический процесс множества БАТ.

Распространенной методикой формирования вектора ИП по результатам анализа импеданса БАТ является исследование ее ВАХ [2, 13]. Такая ВАХ позволяет изучить гистерезисные свойства электропроводимости биообъекта, которые имеют высокую информативность при ранней диагностике различных заболеваний. Однако сам процесс анализа ВАХ в БАТ является достаточно трудоемким, требует значительных затрат времени и не удовлетворяет требованию морфологической интактности [6, 13].

Поэтому в качестве основной задачи настоящей статьи была выбрана разработка методов и средств компьютерного анализа ВАХ БАТ. При этом использовался программно-аппаратный комплекс для анализа ВАХ БАТ на основе модуля L-Card E20-10 [10]. Это дало возможность оперативно и с приемлемым для практики качеством диагностики селективировать (дифференцировать) входные данные по классам состояния биообъектов.

Вычислительная обработка данных. Информацию, заключенную в ВАХ, представим в «пространстве ИП», являющихся наборами векторов, которые соответствуют совокупностям точек ВАХ для различных БАТ. Подбирая соответствующие БАТ и интервал дискретизации для получения точек ВАХ в них, можно построить достаточно гибкие интеллектуальные системы для диагностики и прогнозирования функционального состояния человека или для постановки конкретного диагноза [13].

В процессе диагностики возникает необходимость в оценке вероятностей альтернативных гипотез. Такие вероятности могут быть выражены либо в баллах, либо в процентах. При этом эксперт имеет возможность оценить апостериорную вероятность нулевой гипотезы (обычно – отсутствие патологии) на фоне известных апостериорных вероятностей альтернативных гипотез. Сравнение указанных вероятностей дает ценную информацию при управлении как профилактическими мероприятиями, так и диагностическими исследованиями. Кроме того, в некоторых случаях это позволяет оперативно оценивать и эффективность (результативность) проводимых лечебных мероприятий [3].

Для реализации рассматриваемой методологии исследований целесообразно использовать вероятностные нейронные сети (PNN) [4]. В основе классификации объектов (состояний) с использованием сети PNN лежит метод Байеса.

Задание цены ошибки классификации (соотношения между ошибками первого и второго рода) требует хорошего знания приложения. Однако часто эти цены выбираются одинаковыми для всех классов. Игнорирование различий цен ошибок и априорных вероятно-

стей для различных гипотез все же не избавляет от необходимости оценки функции плотности распределения вероятностей. Оценить эту функцию можно с помощью метода Парцена [14]. В нем используется весовая функция, имеющая центр в точке, представляющей учебный образец. Такая весовая функция называется *функцией потенциала* или *ядром*. Чаще всего в качестве ядра используется *функция Гаусса* [11].

Согласно этому методу для каждого неизвестного образца строится функция Гаусса с центром в точке, соответствующей равенству векторов неизвестного образца X и i -го образца X^i , относящегося к одному из выделяемых классов, то есть:

$$f(X) = \exp(-\|X - X^i\|^2 / \sigma^2), \quad (1)$$

где σ – ширина функции активации (настраиваемый параметр).

Если к выделенному классу принадлежат λ образцов в обучающей выборке, то согласно методу Парцена оценка функции распределения получается в виде суммы функций Гаусса с центрами в точках. Данные точки соответствуют равенству имеющихся образцов, отнесенных к известному классу, и образца неизвестного класса. Это соответствует:

$$P_{\omega_i}(X) = \sum_{\ell=1}^{\lambda} \exp\left(-\|X - X_{\ell}^i\|^2 / \sigma^2\right). \quad (2)$$

Архитектура нейронной сети (НС) PNN построена на основе НС блочного типа [6]. Характерной особенностью сети PNN является то, что каждый решающий модуль сети (агент) осуществляет двухальтернативную (бинарную) классификацию: объект принадлежит к классу ω_i или объект не принадлежит к классу ω_i . В сети PNN будем иметь столько решающих блоков (агентов), сколько БАТ используется при принятии решения о наличии данного заболевания. На выходе каждого блока PNN будем иметь оценки функции распределения $P_{\omega_i}(X)$ и $P_{\bar{\omega}_i}(X)$, определенные согласно (2).

Структурная схема НС, реализующей вышеописанный подход, приведена на рисунке 1.

Слой суммирования в каждом модуле PNN имеет два нейрона: для классов ω_i и $\bar{\omega}_i$. К любому нейрону слоя суммирования идут связи только от элементов слоя образцов, принадлежащих соответствующему классу. Весовые значения связей, идущих от элементов слоя образцов к нейронам слоя суммирования, фиксируются равными «1». Элемент слоя суммирования просто суммирует выходные значения элементов слоя образцов. Эта сумма дает оценку значения функции плотности распределения вероятностей для совокупности экземпляров соответствующего класса.

На рисунке 1 каждый входной набор данных имеет шесть признаков. Слой образцов имеет по одному элементу для каждого образца из обучающей выборки. Входной слой и слой образцов образуют полносвязную структуру в каждом модуле классификации PNN. Для связей, входящих в элемент слоя образцов, весовые значения устанавливаются равными элементам соответствующего вектора-образца.

Выходы нейронов выходного слоя i -го блока PNN для сети с шестьюкомпонентным вектором ИП, структурная схема которой представлена на рисунке 1, определяются как:

$$P_{\omega_i} = \sum_{k=1}^{K_{\omega_i}} \exp\left(-\sum_{j=1}^6 (w_{\omega_i}^{jk} - x_j)^2 / \sigma_{\omega_i}^2\right), \quad (3)$$

$$P_{\bar{\omega}_i} = \sum_{k=1}^{K_{\bar{\omega}_i}} \exp\left(-\sum_{j=1}^6 (w_{\bar{\omega}_i}^{jk} - x_j)^2 / \sigma_{\bar{\omega}_i}^2\right), \quad (4)$$

где x_j – компоненты вектора неизвестного входного образца, K_{ω_i} – число элементов класса ω_i , $K_{\bar{\omega}_i}$ – число элементов класса $\bar{\omega}_i$.




Рис. 1. Структурная схема гибридной сети PNN-FNN для десяти БАТ

В этих выражениях используется квадрат евклидова расстояния от неизвестного экземпляра до элемента слоя образцов. Значение σ задает ширину функции активности и оказывается очень важным. Поэтому оно чаще всего подбирается в результате эксперимента.

В обучающей выборке содержится K элементов из N классов. Для любого класса i справедливо равенство:

$$K_{oi} + K_{oi}^- = K. \quad (5)$$

Для сети PNN не требуется обучение в том смысле, какое необходимо для сетей с обратным распространением ошибок [8]. Причина – все параметры сети PNN (число элементов и значения весов) определяются непосредственно обучающей выборкой.

Архитектура сети PNN определяется структурой обучающей выборки:

- число входных элементов равно числу признаков (на рисунке 1 их шесть);
- число элементов слоя образцов в каждом модуле классификации равно числу элементов в обучающей выборке K ;
- число элементов слоя суммирования в блоке PNN равно удвоенному числу БАТ, используемых в классификационной модели.

На двух выходах каждого блока в слое PNN присутствуют вероятность P_{ω_i} наличия патологии ω_i и вероятность $P_{\bar{\omega}_i}$ отсутствия патологии, обозначенная как $\bar{P}_{\omega_i}$. При этом, в общем случае, $P_{\omega_i} + P_{\bar{\omega}_i} \neq 1$. Эти вероятности определяются соотношением и расположением в пространстве ИП обучающей выборки, а также выбранной шириной функций активации в уравнениях (3) и (4).

Для принятия окончательного решения к вероятностному слою НС PNN добавляется слой, выполненный по нечеткой технологии – FNN. Работа этого слоя основана на нечеткой логике принятия решений [8].

Слой FNN имеет типовую структуру нечеткой НС и содержит три слоя: слой фаззификаторов, слой агрегаторов и дефаззификатор.


Слой фаззификаторов выполняет нелинейное преобразование выходов блока PNN:

$$\mu_{\omega_i, i} = f(P_{\omega_i}(Xi)), \quad (6)$$

где i – номер БАТ, Xi – вектор ИП, полученный по i -ой БАТ.

В частном случае в качестве (6) может быть использован повторитель или масштабирующее преобразование.

На рисунке 2 показаны возможные виды нелинейных преобразований (6), которые могут применяться в фаззификаторах блока FNN.



а) б)
 Рис 2. Нелинейные преобразования в фаззификаторе

Нелинейные преобразования фаззификатора позволяют акцентировать значения функций принадлежности либо на малых, либо на больших значениях вероятностей. Эти нелинейные преобразования могут подбираться эмпирически или рассчитываться аналитически. Например, для подчеркивания (акцентирования) больших значений вероятностей используется выражение:

$$\mu 1(P) = \alpha P^\gamma, \quad (7)$$

а для подчеркивания малых значений вероятностей – выражение:

$$\mu 2(P) = \alpha [1 - (1 - P)^\gamma], \quad (8)$$

где $\gamma \geq 1$, а коэффициент $\alpha \leq 1$ позволяет учитывать информативность БАТ при диагностике выбранной патологии.

Аппроксимации нелинейного преобразования фаззификатора зависимостями (7) и (8) удобны тем, что они имеют два управляемых параметра. Первый из них (α) отражает уровень доверия – эмпирический опыт эксперта в отношении соответствующей группы признаков, а второй (γ) – может быть настроен при наличии обучающей выборки.

На рисунке 2а сплошная кривая, соответствующая преобразованию (7) и штриховая, соответствующая формуле (8), получены при значениях $\alpha = 0,8$ и $\gamma = 7$. На рисунке 2б аналогичные кривые получены при значениях $\alpha = 0,9$ и $\gamma = 2$, а штрих-пунктирная прямая соответствует $\gamma = 1$.

Каждый фаззификатор FNN имеет два входных нейрона. В первом из них осуществляется нелинейное преобразование вероятности наличия патологии ω_i , а во втором – вероятности отсутствия этой патологии.

Агрегаторы второго слоя FNN построены таким образом, чтобы нечеткая операция, которая в них осуществляется, была аналогична операции сложения вероятностей или алгебраического сложения. Выполнение этого требования достигается тем, что на нейроны первого слоя модулей макрослоя FNN поступают свидетельства, подтверждающие одно и то же событие. Это значит, что на первый нейрон должна поступать информация, подтверждающая наличие патологии ω_i , а на второй – подтверждающая отсутствие патологии, т.е. $\bar{\omega}_i$.

Конкретная нечеткая операция в узлах FNN первого слоя определяется посредством обучения модулей FNN и экспертной коррекции функций субъективной плотности вероятностей на выходе макрослоя PNN.

Третий слой модуля FNN содержит всего лишь один нейрон, который исполняет роль дефаззификатора в системе нечеткого логического вывода. Нечеткие операции, выполняемые в узлах FNN, при отсутствии или недостатке экспертных данных могут быть определены на основе методики, основанной на использовании генетических алгоритмов и описанной в [8].

Если договориться с экспертами, что вероятность по каждой БАТ способна только подтверждать диагноз, то уверенность в этом решении по всем исследуемым БАТ для класса (заболевания) ω_ℓ может быть определена по формуле алгебраического сложения:

$$K_{\omega_\ell}(i+1) = K_{\omega_\ell}(i) + \mu_{\omega_\ell}(P_{\omega_\ell}(X(i+1)))(1 - K_{\omega_\ell}(i)), \quad (9)$$

где K_{ω_ℓ} – уверенность в том, что образец принадлежит к классу ω_ℓ ($0 \leq K_{\omega_\ell} \leq 1$);

$K_{\omega_\ell}(1) = \mu_{\omega_\ell}(P_{\omega_\ell}(X1))$; i – номер БАТ.

Дефаззификатор FNN работает на основе «наивного Байеса» согласно выражению (10):

$$h_{\omega_\ell} \cdot c_{\omega_\ell} \cdot K_{\omega_\ell} > h_{\bar{\omega}_\ell} \cdot c_{\bar{\omega}_\ell} \cdot K_{\bar{\omega}_\ell}, \quad (10)$$

где h – априорная вероятность соответствующего класса, c – цена ошибки классификации, K – числовое значение на выходе агрегатора.

Пример решения диагностической задачи с помощью программно-аппаратного комплекса для анализа ВАХ БАТ на основе модуля L-Card E20-10. Для апробации методики была выбрана задача диагностики пиелонефрита у беременных женщин. Инструментальные методы диагностики пиелонефрита при беременности, в том числе катетеризацию мочеточников и почечных лоханок, применяют редко. Опасным считают даже выполнение беременным надлобковой пункции мочевого пузыря для взятия мочи на анализ. Это связано с возможным изменением топографо-анатомических взаимоотношений мочевых и половых органов во время беременности [9].

В связи с вышеописанными сложностями в качестве диагностических признаков пиелонефрита нами использовались ВАХ БАТ, расположенных по меридианам, указанным ниже. В качестве классификаторов применялись многоагентные системы классификации.

Исследование выполнялись в два этапа. На первом из них с помощью однофакторного дисперсионного анализа доказывалась возможность использования построенного пространства ИП для диагностики пиелонефрита у беременных женщин. На втором этапе на контрольных выборках проверялась эффективность методов и средств диагностики пиелонефрита.

При выполнении экспериментальных исследований на первом этапе были сформированы две выборки по двадцать объектов в каждой: 1 – здоровые беременные женщины; 2 – беременные женщины, больные пиелонефритом. Класс не беременных женщин, больных пиелонефритом, в данном случае не рассматривается, так как диагностические исследования таких пациентов могут быть осуществлены известными методами (без использования ВАХ БАТ).

Для каждого объекта из исследуемых выборок были получены ВАХ БАТ из трех меридианов: меридиан сердца – БАТ С7; меридиан легких – БАТ Р9; меридиан перикарда – БАТ МС7 [5]. После получения соответствующих ВАХ они аппроксимировались полиномами седьмого порядка.

Для обоснования выбора модели ВАХ БАТ применялся факторный анализ в пакете STATISTICA 6. Таблица экспериментальных данных была получена по результатам исследования ВАХ БАТ С7 (шэнь-мэнь) меридиана сердца у двадцати волонтеров, не страдающих хроническими заболеваниями.

Выбор числа факторов (они определяют число независимых переменных модели и, соответственно, степень полинома, аппроксимирующего ВАХ) был осуществлен на основе критерия Кайзера (Kaiser, 1960), согласно которому оставляются факторы с собственными значениями большими «1» и критерия осыпи Кэттелла (Cattell, 1966).

Обучающие и контрольные выборки формировались на основе экспертных оценок специалистов урологического отделения Больницы скорой медицинской помощи г. Курска.

Эффективность диагностических решающих правил проверялась путем исследования и сравнительной оценки показателей качества диагностики пиелонефрита моделями многоагентных мобильных интеллектуальных систем с различным числом агентов на нижнем уровне (с различным числом анализируемых БАТ). В качестве расчетных показателей эффективности диагностических решающих правил использовались общепринятые в медицинской практике показатели качества диагностики: диагностическая чувствительность (ДЧ); диагностическая специфичность (ДС); диагностическая эффективность решающего правила (ДЭ).

В работе, описанной в данной статье, программная реализация НС-моделей решающих модулей проводилось с помощью программного обеспечения «Neurowork». «Neurowork» был разработан на кафедре биомедицинской инженерии ЮЗГУ и выполнен в среде MATLAB и FuzzyTech.

Результаты сравнения показателей качества диагностики пиелонефрита у беременных женщин посредством разработанных гибридных интеллектуальных классификаторов приведены на рисунке 3.




Рис. 3. Сравнительная характеристика показателей качества интеллектуальных систем диагностики пиелонефрита

Анализ результатов, представленных на рисунке 3, показывает, что качество принятия решений в целом растет по мере увеличения числа агентов в системе. При этом диагностическая чувствительность двух- и трехагентной моделей практически не отличаются. Диагностическая специфичность возрастает на 10 % при наращивании числа агентов в первом слое гибридной сети PNN-FNN.

Сравнение характеристик (показателей), полученных с использованием многоагентных систем диагностики пиелонефрита, позволяет рекомендовать рассмотренные в статье алгоритмические решения для практического использования в системах выявления урологических заболеваний у беременных женщин.

Выводы.

1. Показано, что в качестве НС при двухальтернативной классификации целесообразно использовать гибридную НС, состоящую из макрослоев со структурой PNN-FNN. Первый макрослой построен на основе вероятностной НС, а второй – на основе нечеткой НС.

2. Предложена PNN – структура вероятностной НС, включающая вероятностные НС блочного типа с двумя скрытыми слоями. Данные слои построены на основе архитектуры радиально-базисных НС, число блоков в которых равно числу исследуемых БАТ или групп ИП.

3. Разработана FNN – структура нечеткой НС для двухальтернативной классификации, состоящая из трех слоев. Первый из них осуществляет нелинейные преобразования выходов PNN; второй – агрегирует выходы первого слоя, согласно принимаемым решениям по диагностируемым классам; третий – выполняет функции дефазификатора.

4. Проведена апробация предложенных методов и средств на примере решения задач диагностики пиелонефрита у беременных женщин посредством многоагентной мобильной системы. Результаты апробации показали, что предлагаемые технологии диагностики могут быть рекомендованы для выявления (подтверждения) урологических заболеваний у беременных женщин.

Список литературы

1. Акулина М. М. Использование точек акупунктуры в автоматизированной системе профилактических осмотров / М. М. Акулина, А. А. Рыбченко, В. Т. Соломонов // Теория и практика рефлексотерапии, медико-биологические и физико-технические аспекты. – Саратов : Саратовский государственный университет имени Н. Г. Чернышевского, 1981. – С. 216–223.
2. Арсеньев В. Е. Исследование возможности диагностики заболеваний человека по вольтамперным характеристикам выделенных участков кожи / В. Е. Арсеньев, А. П. Бердашкевич, А. С. Глазунов // Теория и практика рефлексотерапии, медико-биологические и физико-технические аспекты. – Саратов : Саратовский государственный университет имени Н. Г. Чернышевского, 1981. – С. 232–236.
3. Брумштейн Ю. М. Анализ моделей и методов выбора оптимальных совокупностей решений для задач планирования в условиях ресурсных ограничений и рисков / Ю. М. Брумштейн, Д. А. Тарков, И. А. Дюдилов // Прикаспийский журнал: управление и высокие технологии. – 2013. – № 3. – С. 47–56.
4. Коровин Е. Н. Применение гибридной нейронной сети с макрослоями для классификации сердечно-сосудистых заболеваний / Е. Н. Коровин, О. В. Шаталова, В. В. Жилин // Биомедицинская радиоэлектроника. – 2014. – № 9. – С. 32–37.
5. Лувсан Г. Традиционные и современные аспекты восточной рефлексотерапии / Г. Лувсан. – 3-е изд., перераб. и доп. – Новосибирск : Наука. Сибирское отделение, 1991. – 432 с.
6. Мохаммед Аль-Гунаид. Нейронечеткая модель краткосрочного прогнозирования потребления электроэнергии / Аль-Гунаид Мохаммед // Прикаспийский журнал: управление и высокие технологии. – 2013. – № 2 (22). – С. 47–56.
7. Нечушкин А. И. Физиологические основы функциональной коррекции электропунктурными методами / А. И. Нечушкин // Вопросы медицинской электроники. – 1981. – Вып. 3. – С. 52–56.
8. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы : пер. с польск. / Д. Рутковская, М. Пилиньский, Л. Рутковский ; пер. И. Д. Рудинского. – Москва : Горячая линия Телеком, 2004. – 452 с.
9. Сафронова Л. А. Пиелонефрит и беременность / Л. А. Сафронова // Русский медицинский журнал. – 2000. – Т. 8, № 18 (119). – С. 778–781.
10. Суржикова С. Е. Программно-аппаратный комплекс для анализа вольтамперных характеристик биоактивных точек на основе модуля L-Card E20-10 / С. Е. Суржикова, О. В. Шаталова, В. В. Федянин // Прикаспийский журнал: управление и высокие технологии. – 2015. – № 1. – С. 47–56.
11. Терзиян А. В. Вероятностные метасети для решения задач интеллектуального анализа данных / А. В. Терзиян, В. Я. Витько // Искусственный интеллект. – 2002. – № 3. – С. 188–197.
12. Филист С. А. Диагностическая система на основе анализа вольтамперных характеристик биоактивных точек / С. А. Филист, Н. А. Корневский, О. В. Шаталова и другие // Биотехносфера. – 2013. – № 5 (29). – С. 33–38.
13. Филист С. А. Метод исследования электрических характеристик биоактивных точек / С. А. Филист, С. Е. Суржикова, Д. А. Кассим Кабус // Научный взгляд на современный этап развития общественных, технических, гуманитарных и естественных наук. Актуальные проблемы : сборник статей по итогам Всероссийской научно-практической конференции. – Санкт-Петербург, 2014. – С. 118–122.
14. Parzen E. An estimation of a probability density function and mode / E. Parzen // The Annals of Mathematical Statistics. – 1962. – Vol. 33, № 3. – P. 1065–1076.

References

1. Akulina M. M., Rybchenko A. A., Solomonov V. T. Ispolzovanie tochek akupunktury v avtomatizirovannoy sisteme profilakticheskikh osmotrov [Use of acupuncture points in the automated system of preventive examinations]. *Teoriya i praktika refleksoterapii, mediko-biologicheskie i fiziko-tekhnicheskie aspekty* [Theory and Practice of Acupuncture, Medical and Biological, and Physical and Technical Aspects], Saratov, Saratov State University named after N. G. Chernyshevsky Publ. House, 1981, pp. 216–223.
2. Arsenev V. Ye., Berdashkevich A. P., Glazunov A. S. Issledovanie vozmozhnosti diagnostiki zabolevaniy cheloveka po voltampernym kharakteristikam vydelennykh uchastkov kozhi [Study of diagnostics of diseases of the human voltage-current characteristics of the selected areas of the skin]. *Teoriya i praktika refleksoterapii, mediko-biologicheskie i fiziko-tekhnicheskie aspekty* [Theory and Practice of Acupuncture,

Medical and Biological, and Physical and Technical Aspects]. Saratov, Saratov State University named after N. G. Chernyshevsky Publ. House, 1981, pp. 232-236.

3. Brumshteyn Yu. M., Tarkov D. A., Dyudikov I. A. Analiz modeley i metodov vybora optimalnykh sovokupnostey resheniy dlya zadach planirovaniya v usloviyakh resursnykh ogranicheniy i riskov [Analysis of models and methods for the selection of optimal sets of solutions for planning tasks in the context of resource constraints and risks]. *Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian Journal: Management and High Technologies], 2013, no. 3, pp. 47–56.

4. Korovin Ye. N., Shatalova O. V., Zhilin V. V. Primenenie gibridnoy neyronnoy seti s makrosloyami dlya klassifikatsii serdechno-sosudistyykh zabolevaniy [Application of hybrid neural network macroslope for the classification of cardiovascular diseases]. *Biomeditsinskaya radioelektronika* [Biomedical Radio Electronics], 2014, no. 9, pp. 32–37.

5. Luvsan G. Traditsionnye i sovremennyye aspekty vostochnoy refleksoterapii [Traditional and modern aspects of Eastern reflexotherapy], 3rd ed., rev. and add. Novosibirsk, Nauka. Sibirskoe otdelenie Publ., 1991. 432 p.

6. Mokhammad Al-Gunaid. Neyronechetskaya model kratkosrochnogo prognozirovaniya potrebleniya elektroenergii [Article the fuzzy neural network model for short-term forecasting of electricity consumption]. *Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian Journal: Management and High Technologies], 2013, no. 2 (22), pp. 47–56.

7. Nechushkin A. I. Fiziologicheskie osnovy funktsionalnoy korrektsii elektropunktturnymi metodami [Physiological basis of functional correction methods of electroacupuncture]. *Voprosy meditsinskoj elektroniki* [Problems of Medical Electronics], 1981, issue 3, pp. 52–56.

8. Rutkovskaya D., Pilinskiy M., Rutkovskiy L. *Neyronnye seti, geneticheskie algoritmy i nechetkie sistemy* [Neural networks, genetic algorithms and fuzzy systems], Moscow, Goryachaya liniya Telekom Publ., 2004. 452 p.

9. Safronova L. A. Pielonefrit i beremennost [Pyelonephritis and pregnancy]. *Russkiy meditsinskiy zhurnal* [Russian Medical Journal], 2000, vol. 8, no. 18 (119), pp. 778–781.

10. Surzhikova S. Ye., Shatalova O. V., Fedyanin V. V. Programmno-apparatnyy kompleks dlya analiza voltampernykh kharakteristik bioaktivnykh toчек naosnove modulya L-Card E20-10 [Hardware-software complex for the analysis of current-voltage characteristics of bioactive points based on module L-Card E20-10]. *Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian Journal: Management and High Technologies], 2015, no. 1., pp. 47–56.

11. Terziyan A. V., Vitko V. Ya. Veroyatnostnyye metaseti dlya resheniya zadach intellektualnogo analiza dannykh [Probabilistic Metacity for solving data mining]. *Iskusstvennyy intellekt* [Artificial Intelligence], 2002, no. 3, pp. 188–197.

12. Filist S. A., Korenevskiy N. A., Shatalova O. V., et al. Diagnosticheskaya sistema na osnove analiza voltampernykh kharakteristik bioaktivnykh toчек [A Diagnostic system based on the analysis of current-voltage characteristics of bioactive points]. *Biotehnosfera* [Biotechnosphere], 2013, no. 5 (29), pp. 33–38.

13. Filist S. A., Surzhikova S. Ye., Kassim D. A. Kabus Metod issledovaniya elektricheskikh kharakteristik bioaktivnykh toчек [Method of the study of the electrical characteristics of bioactive points]. *Nauchnyy vzglyad na sovremennyy etap razvitiya obshchestvennykh, tekhnicheskikh, gumanitarnykh i estestvennykh nauk. Aktualnye problemy : sbornik statey po itogam Vserossiyskoy nauchno-prakticheskoy konferentsii* [Scientific View on the Current Stage of Development of Social, Technological, Humanitarian and Natural Sciences. Actual Problems. Proceedings of the Results of All-Russian Scientific and Practical Conference], Saint Petersburg, 2014, pp. 118–122.

14. Parzen E. An estimation of a probability density function and mode. *The Annual of Mathematical Statistics*, 1962, vol. 33, no. 3, pp. 1065–1076.