

ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

УДК 004.942

DOI 10.55421/1998-7072_2024_27_11_188

**А. С. Катасёв, Д. В. Катасёва, Д. З. Валиева,
Г. Л. Дегтярев**

**ПОСТРОЕНИЕ И ИССЛЕДОВАНИЕ НЕЙРОНЕЧЕТКОЙ
МОДЕЛИ ДИАГНОСТИКИ САХАРНОГО ДИАБЕТА**

Ключевые слова: сахарный диабет, диагностика, нечеткая нейронная сеть, нейронечеткая модель, набор данных, формирование базы знаний.

В статье описывается решение задачи построения и исследования нейронечеткой модели, используемой для диагностики сахарного диабета. В настоящее время наблюдается устойчивая тенденция увеличения распространенности сахарного диабета. Он представляет собой группу заболеваний эндокринной системы, связанных с нарушением усваивания глюкозы в организме. Своевременная диагностика этого заболевания играет ключевую роль в эффективном лечении и профилактике осложнений. Разработка эффективных методов диагностики сахарного диабета является важной задачей, требующей комплексного подхода с использованием современных информационных технологий. Для решения этой задачи целесообразно использование нечетких баз знаний, основанных на нечетко-продукционных правилах, формируемых с помощью нечетких нейронных сетей. Такой подход базируется на принципах нечеткой логики, что позволяет получать интерпретируемые решения. В работе в качестве инструмента формирования баз знаний использована модель нечеткой нейронной сети, показавшая свою эффективность в решении большого количества задач в различных предметных областях. Для обучения нечеткой нейронной сети потребовались исходные данные, в качестве которых выбран набор данных Pima Indians из открытого источника Kaggle. Набор включает в себя 768 записей по 9 параметрам, один из которых является выходным, указывающим на наличие или отсутствие заболевания. В результате предобработки исходных данных выбрано 4 входных параметра, значимо влияющих на выходной. Для обучения нечеткой нейронной сети использован программный комплекс «Нейронечеткая система формирования нечетких моделей оценки дискретного состояния объектов». Из исходных данных сформированы обучающая и тестовая выборки методом группового случайного сэмплинга с замещением. Для обучения использованы треугольные функции принадлежности. В ходе обучения нечеткая нейронная сеть прошла 9 полных итераций, длившихся в общей сложности 55 минут 32 секунды. За каждую итерацию алгоритм обрабатывал по 38 параметров функций принадлежности. Для обучающей выборки точность классификации составила 86,72%, для тестовой – 73,33%. В ходе обучения проведены дополнительные исследования по оценке влияния параметров генетического алгоритма на адекватность нейронечеткой модели. Результаты исследований позволили сформулировать рекомендации по выбору параметров обучения нечеткой нейронной сети. Сравнение полученных результатов с известными результатами других авторов позволило сделать вывод, что нейронечеткая модель является эффективной для решения задачи диагностики сахарного диабета. В дальнейшем построенную модель можно интегрировать в интеллектуальную систему и использовать в диагностической деятельности врачей.

**A. S. Katasev, D. V. Kataseva, D. Z. Valieva,
G. L. Degtyarev**

**CONSTRUCTION AND STUDY OF A NEURO-FUZZY MODEL
FOR DIAGNOSIS OF DIABETES MELLITUS**

Keywords: diabetes mellitus, diagnostics, fuzzy neural network, neuro-fuzzy model, data set, knowledge base formation.

The article describes the solution to the problem of constructing and studying a neuro-fuzzy model used to diagnose diabetes mellitus. Currently, there is a steady trend of increasing prevalence of diabetes mellitus. It is a group of endocrine diseases associated with impaired glucose absorption in the body. Timely diagnosis of this disease plays a key role in effective treatment and prevention of complications. The development of effective methods for diagnosing diabetes mellitus is an important task that requires an integrated approach using modern information technologies. To solve this problem, it is advisable to use fuzzy knowledge bases based on fuzzy-production rules formed using fuzzy neural networks. This approach is based on the principles of fuzzy logic, which allows you to obtain interpretable solutions. In this work, a fuzzy neural network model was used as a tool for forming knowledge bases, which has proven its effectiveness in solving a large number of problems in various subject areas. To train the fuzzy neural network, initial data was required, for which the Pima Indians dataset from the open source Kaggle was selected. The set includes 768 records for 9 parameters, one of which is an output parameter indicating the presence or absence of a disease. As a result of preprocessing of the initial data, 4 input parameters were selected that significantly affect the output parameter. The fuzzy neural network was trained using the software package "Neuro-fuzzy system for generating fuzzy models for assessing the discrete state of objects". Training and test samples were formed from the initial data using the group random sampling with replacement method. Triangular membership functions were used for training. During training, the fuzzy neural network went through 9 full iterations, which lasted a total of 55 minutes 32 seconds. For each iteration, the algorithm processed 38 parameters of the membership functions. For the training sample, the classification accuracy was 86.72%, for the test sample - 73.33%. During training, additional studies were

conducted to assess the influence of the genetic algorithm parameters on the adequacy of the neuro-fuzzy model. The research results made it possible to formulate recommendations for choosing the training parameters of the fuzzy neural network. Comparison of the obtained results with known results of other authors allowed to conclude that the neuro-fuzzy model is effective for solving the problem of diabetes diagnosis. In the future, the constructed model can be integrated into an intelligent system and used in the diagnostic activities of doctors.

Введение

В настоящее время наблюдается устойчивая тенденция увеличения распространенности сахарного диабета в России. На конец 2021 года на диспансерном учете состояло примерно 3,34% населения страны [1]. При этом значительная часть случаев сахарного диабета (92,3%) приходится на диабет второго типа [2].

Сахарный диабет представляет собой группу заболеваний эндокринной системы, связанных с нарушением усваивания глюкозы в организме. Это происходит из-за недостатка инсулина, необходимого для усвоения глюкозы клетками, либо из-за ухудшенной чувствительности клеток к этому гормону. В результате клетки остаются без необходимого питания, несмотря на избыток глюкозы в крови. Сахарный диабет является серьезной медико-социальной проблемой, характеризующейся высокой распространенностью и значительными затратами на лечение и профилактику осложнений. Данное заболевание существенно ухудшает качество жизни пациентов, ограничивая их повседневную активность и социальное функционирование.

Современная медицина сталкивается с проблемой позднего выявления сахарного диабета [3]. Своевременная диагностика данного заболевания играет ключевую роль в эффективном лечении и профилактике осложнений. Для постановки диагноза сахарного диабета медицинские специалисты осуществляют всесторонний клинический осмотр пациента. Они тщательно анализируют жалобы больного, изучают его медицинскую документацию, включая семейный анамнез, а также проводят физикальное и лабораторное обследование. Окончательная постановка диагноза во многом зависит от результатов лабораторных исследований. Многие осложнения, связанные с диабетом, такие как нефропатия, ретинопатия, невропатия, сердечно-сосудистые заболевания, можно отсрочить или предотвратить с помощью своевременного выявления болезни [4].

Разработка эффективных методов диагностики сахарного диабета является важной задачей, требующей комплексного подхода с использованием современных информационных технологий [5-7]. Для решения этой задачи целесообразно использование нечетких баз знаний [8-10], основанных на нечетко-продукционных правилах [11, 12], формируемых с помощью нечетких нейронных сетей [13-16]. Данный подход базируется на принципах нечеткой логики [17, 18], что позволяет получать интерпретируемые решения с помощью модуля логического вывода [19, 20].

В данной работе в качестве инструмента формирования баз знаний использована модель нечеткой нейронной сети, показавшая свою эффективность в решении большого количества задач в различных

предметных областях [21-24]. Оценка ее эффективности для диагностики сахарного диабета потребовала проведения дополнительных исследований, связанных с анализом исходных данных и построением нейронечеткой модели при различных вариантах параметрической оптимизации [25, 26].

Данные для построения нейронечеткой модели

Для обучения нечеткой нейронной сети требуются исходные данные [27]. Данные для исследования Pima Indians [28] были получены из открытого источника – репозитория машинного обучения Kaggle [29]. Набор данных о диабете подготовлен Национальным институтом диабета, гастроэнтерологии и почечных заболеваний США. Цель этого набора – диагностически прогнозировать, есть ли у пациента диабет, основываясь на определенных диагностических и клинических показателях. Набор включает в себя 768 записей по 9 параметрам. Восемь из них являются входными, отражающими различные характеристики, полученными в ходе исследований и измерений, которые могут указывать на наличие сахарного диабета:

- количество беременностей;
- глюкоза – концентрация глюкозы в плазме крови, измеренная через 2 часа после прохождения орального глюкозотолерантного теста (мг/дл);
- артериальное давление (мм рт. ст.);
- толщина кожи – толщина кожно-жировой складки в области трицепса (мм);
- инсулин (мкг/мл);
- ИМТ - индекс массы тела (кг/м²);
- ФРД – функция родословной диабета, использующая информацию о наличии диабета у родственников исследуемого;
- возраст (в годах).

Один параметр является выходным, указывающим на наличие (1) или отсутствие (0) заболевания.

Проверка качества набора данных и их подготовка к анализу осуществлена при помощи программы Deductor Academic, которая обладает широкими возможностями визуализации данных и импорта из различных источников. Оценка качества данных показала необходимость их предварительной очистки и подготовки для анализа. В частности, потребовалась обработка выбросов и экстремальных значений. Дубликаты и противоречия в исходных данных обнаружены не были.

Для определения степени влияния каждого входного параметра на выходной результат в программе Deductor была проведена процедура корреляционного анализа [30]. Получившаяся матрица коррелированности входных и выходного параметров представлена на рисунке 1.

Входные поля	Корреляция с выходными полями
Поле	Результат
Кол-во беременностей	0,198
Глюкоза	0,477
Артериальное давление	0,114
Толщина кожи	0,065
Инсулин	0,125
ИМТ	0,309
ФРД	0,184
Возраст	0,242

Рис. 1 – Матрица корреляции входных параметров с выходным

Fig. 1 – Correlation matrix of input parameters with output

Согласно матрице корреляции, наименее значащими входными параметрами являются «толщина кожи», «артериальное давление», «инсулин» и «функция родословной диабета». Эти параметры были исключены из выборки. В результате получился набор данных, содержащий 4 входных параметра: «количество беременностей», «глюкоза», «индекс массы тела», «возраст» и 1 выходной параметр – «результат», указывающий на наличие (1) или отсутствие (0) сахарного диабета.

Обучение нечеткой нейронной сети

Для обучения нечеткой нейронной сети использован программный комплекс «Нейронечеткая система формирования нечетких моделей оценки дискретного состояния объектов» [31], позволяющий осуществлять загрузку данных, задавать число градаций входных параметров, создавать обучающую и тестовую выборки, строить функции принадлежности и нечетко-продукционные правила.

Экспертным путем определено число градаций для входных параметров. Для количества беременностей и возраста установлено по 5 градаций, поскольку эти параметры отличаются широким спектром значений. Для индекса массы тела и уровня глюкозы – по 4 градации, что обусловлено более ограниченным диапазоном их значений. Таким образом, количество градаций для каждого параметра определялось с учетом особенностей распределения и разнообразия их значений. Следует отметить, что применение большего количества градаций может значительно увеличить время обработки данных, при этом точность классификации может незначительно повыситься либо не измениться.

Из исходных данных сформированы обучающая и тестовая выборки методом группового случайного сэмплинга с замещением [32, 33], который показал свою эффективность, обеспечивая однородность анализируемых данных. Для обучения использованы треугольные функции принадлежности. Их настройка проводилась при помощи генетического алгоритма, параметры которого представлены на рисунке 2.

Процесс обучения нечеткой нейронной сети сопровождается построением графиков изменения точности классификации на обучающей и тестовой выборках данных (см. рис. 3).

На графике верхняя кривая характеризует изменение точности классификации на обучающей выборке данных, а нижняя – на тестовой выборке.

Обучение ННС

Число ННС: 5

Длина хромосомы в ГА: 10

Число хромосом в ГА: 150

Вероятность мутации дочерних хромосом, %: 10,0

Число эпох холостой работы ГА: 5

Число циклов холостого обучения ННС: 2

Рис. 2 – Окно настройки параметров генетического алгоритма

Fig. 2 – Genetic algorithm parameters settings window

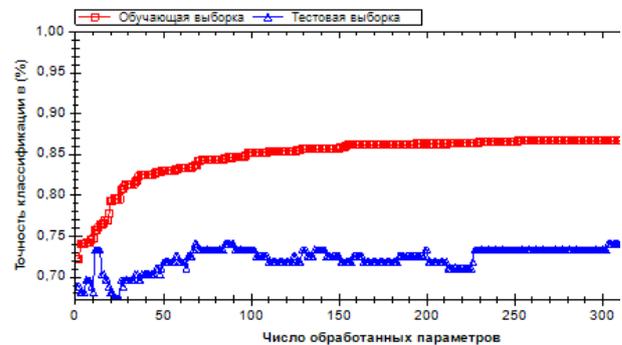


Рис. 3 – График обучения нейронечеткой модели

Fig. 3 – Neuro-fuzzy model training schedule

Результаты обучения нечеткой нейронной сети представлены на рисунке 4.

Результаты обучения ННС

Цикл обучения ННС: 9

Параметр ФП / всего параметров: 38 / 38

Эпоха ГА (настройка параметра): 11

Время обучения ННС (чч:мм:сс): 00:55:32

Точность классификации, % (train): 86,72

Точность классификации, % (test): 73,33

Рис. 4 – Результаты обучения нечеткой нейронной сети

Fig. 4 – Results of training fuzzy neural network

В ходе обучения нечеткая нейронная сеть прошла 9 полных итераций, длившихся в общей сложности 55 минут 32 секунды. За каждую итерацию алгоритм обрабатывал по 38 параметров функций принадлежности. В результате обучения удалось добиться повышения точности классификации на каждой выборке данных. Для обучающей выборки точность классификации составила 86,72%, для тестовой – 73,33%.

Исследование нейронечеткой модели и оценка ее адекватности

В ходе обучения нечеткой нейронной сети проведены дополнительные исследования по оценке влияния параметров генетического алгоритма на адекватность нейронечеткой модели. Для этого экспериментально подобраны следующие значения длины хромосомы: 9, 10, 11. Результаты влияния длины хромосомы на показатели обучения нечеткой нейронной сети представлены в таблице 1.

Таблица 1 – Зависимость результатов обучения нечеткой нейронной сети от длины хромосомы

Table 1 – Dependence of fuzzy neural network training results on the chromosome length

Длина хромосомы	Значения метрик качества классификации				Время обучения
	Accuracy (OB/TB)	Precision (OB/TB)	Recall (OB/TB)	F1-Score (OB/TB)	
9	0,8372/ 0,7463	0,8194/ 0,725	0,83/ 0,7378	0,824/ 0,725	00:55:54
10	0,8581/ 0,7122	0,8426/ 0,6789	0,8477/ 0,6861	0,845/ 0,6818	01:01:36
11	0,8516/ 0,7292	0,8414/ 0,6968	0,8272/ 0,6861	0,8333/ 0,6903	01:40:29

В таблице OB – это обучающая выборка, а TB – тестовая выборка.

Проведенное исследование показало, что увеличение длины хромосомы приводит к росту времени обучения, а также способствует повышению точности классификации. Оптимальная длина хромосомы для достижения наивысшей точности классификации составила 10. Увеличение длины хромосомы не привело к повышению точности, но при этом потребовало больших временных затрат на обучение.

В ходе обучения сети экспериментально подобраны следующие значения числа хромосом в генетическом алгоритме: 100, 150, 200. Результаты влияния числа хромосом на показатели обучения сети представлены в таблице 2.

Таблица 2 – Зависимость результатов обучения нечеткой нейронной сети от числа хромосом

Table 2 – Dependence of fuzzy neural network training results on the number of chromosomes

Число хромосом	Значения метрик качества классификации				Время обучения
	Accuracy (OB/TB)	Precision (OB/TB)	Recall (OB/TB)	F1-Score (OB/TB)	
100	0,8268/ 0,7071	0,8299/ 0,6824	0,8294/ 0,69	0,821/ 0,6852	00:35:42
150	0,8215/ 0,7146	0,8147/ 0,7142	0,8147/ 0,7142	0,8234/ 0,7209	00:46:14
200	0,8151/ 0,7483	0,7966/ 0,7287	0,7966/ 0,7039	0,7966/ 0,7116	00:44:07

Согласно проведенным исследованиям, варьирование количества хромосом в генетическом алгоритме не оказывает существенного влияния на продолжительность обучения нечеткой нейронной сети. Однако, при увеличении числа хромосом от 150 до 200 наблюдается незначительное снижение точности классификации на обучающей выборке данных. Оптимальное число хромосом в генетическом алгоритме составило 150. Данное значение обеспечивает максимальную точность классификации.

В ходе обучения нечеткой нейронной сети также были экспериментально подобраны следующие значения вероятности мутации генов дочерних хромосом: 5%, 10% и 15%. Проведенные исследования показали, что изменение значения этого показателя практически не отразилось на точности классификации и времени построения модели.

Число эпох холостой работы генетического алгоритма также не являлось критическим, так как не влияло на точность классификации данных. Однако, наблюдалось линейное увеличение времени, затрачиваемого на обучение нечеткой нейронной сети. Оптимальное количество эпох холостой работы генетического алгоритма составило 5.

Согласно полученным результатам были сформулированы следующие рекомендации по выбору параметров обучения нечеткой нейронной сети:

- количество градаций входных параметров: 4-5;
- длина хромосомы: 10;
- количество хромосом: 150;
- вероятность мутации дочерних хромосом: 10%;
- количество эпох холостой работы генетического алгоритма: 5.

На основе этих рекомендаций произведено обучение пяти нечетких нейронных сетей. Значения метрик качества классификации после обучения представлены в таблице 3.

Таблица 3 – Результаты обучения нечетких нейронных сетей

Table 3 – Results of training a fuzzy neural networks

Номер ННС	Значения метрик качества классификации			
	Accuracy (OB/TB)	Precision (OB/TB)	Recall (OB/TB)	F1-Score (OB/TB)
ННС №1	0,8634 / 0,7341	0,8512/ 0,7213	0,8682/ 0,7283	0,8574/ 0,7254
ННС №2	0,841/ 0,7487	0,8218/ 0,7454	0,8311/ 0,7482	0,8344/ 0,7421
ННС №3	0,8516/ 0,7292	0,8414/ 0,6968	0,8272/ 0,6861	0,8333/ 0,6903
ННС №4	0,8789 / 0,6901	0,8819/ 0,6539	0,8482/ 0,6539	0,8612/ 0,6539
ННС №5	0,8581/ 0,7122	0,8426/ 0,6789	0,8477/ 0,6861	0,845/ 0,6818

Анализ полученных результатов свидетельствует об адекватности построенных моделей. Достигнутая точность классификации нечеткой нейронной сети на обучающей выборке данных составила 0,8789.

Сравнительный анализ результатов исследования с другими подходами

Набор данных Pima Indians [34] является предметом пристального внимания среди исследователей, занимающихся машинным обучением [35]. Многочисленные научные работы [36-38] посвящены применению различных методов машинного обучения для диагностики сахарного диабета, включая логистическую регрессию [39], деревья решений [40], случайные леса [41], опорные вектора [42] и нейронную сеть [43]. Результаты этих исследований представлены в таблице 4.

Таблица 4 – Результаты исследований набора данных Pima Indians

Table 4 – Results of the Pima Indians dataset research

Метод анализа	Значения метрик качества классификации			
	Accuracy	Precision	Recall	F1-Score
Логистическая регрессия	0,81	0,77	0,61	0,68
Деревья решений	0,75	0,64	0,54	0,58
Случайные леса	0,78	0,75	0,72	0,73
Опорные вектора	0,78	0,73	0,61	0,67
Нейронная сеть	0,85	0,84	0,82	0,83

Несмотря на то, что традиционные методы продемонстрировали высокие показатели качества классификации при работе с используемым набором данных, указанные значения метрик уступают результатам, полученным с использованием нейронечеткой модели. Это свидетельствует о том, что такая модель является более эффективной для решения задачи диагностики сахарного диабета.

Заключение

Исследование показало эффективность нейронечеткого подхода к решению поставленных задач. Нечеткие нейронные сети могут быть использованы в качестве интеллектуального инструмента для диагностики сахарного диабета, обеспечивая высокую точность, скорость и доступность данного медицинского процесса. В дальнейшем построенную нейронечеткую модель можно интегрировать в интеллектуальную систему и эффективно использовать в диагностической деятельности врачей.

Литература

- Н.И. Марков, *Медицинский совет*, 6, 42-63 (2023).
- Е.Г. Потапчик, *Профилактическая медицина*, 8, 15-22 (2021).
- С.И. Исмаилов, А.В. Алиева, *Журнал теоретической и клинической медицины*, 6, 42-48 (2016).
- Е.С. Ярошенко, *Эндокринология. Новости. Мнения. Обучение*, 8, 3 (28), 117-119 (2019).
- О.Ю. Номоконова, *Славянский форум*, 3 (45), 139-149 (2024).
- Т.Т. Камалов, Ф.М. Тураханова, *Международный эндокринологический журнал*, 1 (73), 39-46 (2016).
- С.С. Сафарова, *Медицинский алфавит*, 2, 21 (396), 43-46 (2019).
- Д.В. Катасёва, А.О. Барина, *Вестник Технологического университета*, 25, 2, 67-70 (2022).
- М.М. Chupin, A.S. Katasev, A.M. Akhmetvaleev, D.V. Kataseva, *International Journal of Supply Chain Management*, 8, 5, 201-208 (2019).
- Е.Н. Коровин, *Системный анализ и управление в биомедицинских системах*, 20, 3, 90-95 (2021).
- А.Р. Абдулхаков, А.С. Катасёв, А.П. Кирпичников, *Вестник Казанского технологического университета*, 17, 23, 389-392 (2014).
- А.С. Катасёв, *Автоматизация процессов управления*, 1 (55), 21-29 (2019).
- Н.Н. Зиятдинов, Л.М. Дмитриева, А.Е. Сережкина, М.Е. Дмитриев, *Вестник Технологического университета*, 18, 2, 357-361 (2015).
- Q. Chen, I.E. Grossmann, N.N. Ziyatdinov, I.I. Emel'yanov, *Computers & Chemical Engineering*, 142, 107042 (2020).
- Н.Р. Кашапов, А.С. Катасёв, Д.В. Катасёва, *Информация и безопасность*, 19, 4, 555-558 (2016).
- А.С. Катасёв, Ч.Ф. Ахатова, *Программные продукты и системы*, 3, 6-12 (2011).
- И.Ю. Мышкина, А.З. Асанов, *Качество. Инновации. Образование*, 12 (67), 43-51 (2010).
- Л.Ю. Емалетдинова, С.В. Новикова, *Программные системы и вычислительные методы*, 2, 151-159 (2013).
- М.В. Дагаева, Д.В. Катасёва, А.С. Катасёв, А.П. Кирпичников, *Вестник Технологического университета*, 21, 2, 148-154 (2018).
- А.С. Катасёв, *Вестник Казанского государственного технического университета им. А.Н. Туполева*, 4, 212-217 (2013).
- А.О. Барина, Д.В. Катасёва, А.С. Катасёв, *Вестник Технологического университета*, 23, 10, 75-78 (2020).
- А.С. Катасёв, Д.В. Катасёва, А.П. Кирпичников, Я.Е. Семёнов, *Вестник Технологического университета*, 18, 15, 217-220 (2015).
- А.С. Катасёв, *Научно-технический вестник Поволжья*, 5, 191-194 (2013).
- В.И. Глова, А.С. Катасёв, Г.С. Корнилов, *Информационные технологии*, 5, 15-19 (2010).
- С.В. Новикова, *Вестник Казанского государственного энергетического университета*, 14, 3 (55), 114-125 (2022).
- G.M. Ostrovsky, N.N. Ziyatdinov, T.V. Lapteva, *Chemical Engineering Science*, 65, 7, 2373-2381 (2010).
- Л.Ю. Грудцына, И.Ю. Мышкина, *Научно-технический вестник Поволжья*, 3, 100-103 (2016).
- A. Darolia, R.S. Chhillar, *ECS Transactions*, 107, 1, 2697-2704 (2022).
- M. Kuroki, *Journal of Economic Education*, 54, 4, 364-378 (2023).
- С.В. Бочкарев, Е.С. Обухов, *Фундаментальные исследования*, 11-3, 476-481 (2016).
- А.С. Катасёв, *Кибернетика и программирование*, 6, 110-122 (2018).
- А.И. Барин, Д.В. Катасёва, А.С. Катасёв, *Вестник Технологического университета*, 23, 10, 64-67 (2020).
- Л.А. Демидова, М.М. Егин, Ю.С. Соколова, *Cloud of Science*, 4, 4, 572-592 (2017).
- A. Gregory, T. Jones, *Journal of Southwestern Anthropology and History*, 88, 1, 144-146 (2022).
- О.А. Пырнова, *Научно-технический вестник Поволжья*, 11, 254-256 (2023).
- Ch. Porter, *Southwestern Historical Quarterly*, 125, 4, 510-511 (2022).
- H.P. Daly, *Western Historical Quarterly*, 54, 1, 93-98 (2023).

38. J. Bess, *Journal of Anthropological Research*, **78**, 2, 244-246 (2022).
39. A. Velu, M. Thangavelu, *Computers, Materials and Continua*, **71**, 1, 457-471 (2022).
40. Ch. Azad, B. Bhushan, R. Sharma, A. Shankar, *Multimedia Systems*, **28**, 4, 1289-1307 (2022).
41. F. Mustofa, A.N. Safriandono, *Journal of Computing Theories and Applications*, **1**, 1, 41-48 (2023).
42. B.S. Bahnam, S.A. Dawwod, *International Journal of Artificial Intelligence*, **11**, 3, 1164-1175 (2022).
43. D.A. Pustokhin, I.V. Pustokhina, M. Ilayaraja, *Studies in Fuzziness and Soft Computing*, **413**, 41-55 (2022).

References

1. N.I. Markov, *Medical Council*, 6, 42-63 (2023).
2. E.G. Potapchik, *Preventive Medicine*, 8, 15-22 (2021).
3. S.I. Ismailov, A.V. Alieva, *Journal of Theoretical and Clinical Medicine*, 6, 42-48 (2016).
4. E.S. Yaroshenko, *Endocrinology. News. Opinions. Training*, **8**, 3 (28), 117-119 (2019).
5. O.Y. Nomokonova, *Slavic Forum*, 3, 139-149 (2024).
6. T.T. Kamalov, F.M. Turakhanova, *International Journal of Endocrinology*, 1 (73), 39-46 (2016).
7. S.S. Safarova, *Medical Alphabet*, **2**, 21 (396), 43-46 (2019).
8. D.V. Kataseva, A.O. Barinova, *Herald of Technological University*, **25**, 2, 67-70 (2022).
9. M.M. Chupin, A.S. Katasev, A.M. Akhmetvaleev, D.V. Kataseva, *International Journal of Supply Chain Management*, **8**, 5, 201-208 (2019).
10. E.N. Korovin, *Systems Analysis and Management in Biomedical Systems*, **20**, 3, 90-95 (2021).
11. A.R. Abdulkhakov, A.S. Katasev, A.P. Kirpichnikov, *Herald of Kazan Technological University*, **17**, 23, 389-392 (2014).
12. A.S. Katasev, *Automation of control processes*, 1 (55), 21-29 (2019).
13. N.N. Ziyatdinov, L.M. Dmitrieva, A.E. Serezhkina, M.E. Dmitriev, *Herald of Technological University*, **18**, 2, 357-361 (2015).
14. Q. Chen, I.E. Grossmann, N.N. Ziyatdinov, I.I. Emel'yanov, *Computers & Chemical Engineering*, **142**, 107042 (2020).
15. N.R. Kashapov, A.S. Katasev, D.V. Kataseva, *Information and Security*, **19**, 4, 555-558 (2016).
16. A.S. Katasev, Ch.F. Akhatova, *Software products and systems*, 3, 6-12 (2011).
17. I.Yu. Myshkina, A.Z. Asanov, *Quality. Innovations. Education*, 12 (67), 43-51 (2010).
18. L.Yu. Emaletdinova, S.V. Novikova, *Software systems and computational methods*, 2, 151-159 (2013).
19. M.V. Dagaeva, D.V. Kataseva, A.S. Katasev, A.P. Kirpichnikov, *Herald of Technological University*, **21**, 2, 148-154 (2018).

20. A.S. Katasev, *Herald of Kazan State Technical University n.a. A.N. Tupolev*, 4, 212-217 (2013).
21. A.O. Barinova, D.V. Kataseva, A.S. Katasev, *Herald of Technological University*, **23**, 10, 75-78 (2020).
22. A.S. Katasev, D.V. Kataseva, A.P. Kirpichnikov, Ya.E. Semenov, *Herald of Technological University*, **18**, 15, 217-220 (2015).
23. A.S. Katasev, *Scientific and Technical Bulletin of the Volga Region*, 5, 191-194 (2013).
24. V.I. Glova, A.S. Katasev, G.S. Kornilov, *Information Technologies*, 5, 15-19 (2010).
25. S.V. Novikova, *Bulletin of the Kazan State Power Engineering University*, **14**, 3 (55), 114-125 (2022).
26. G.M. Ostrovsky, N.N. Ziyatdinov, T.V. Lapteva, *Chemical Engineering Science*, **65**, 7, 2373-2381 (2010).
27. L.Yu. Grudtyna, I.Yu. Myshkina, *Scientific and Technical Bulletin of Volga Region*, 3, 100-103 (2016).
28. A. Darolia, R.S. Chhillar, *ECS Transactions*, **107**, 1, 2697-2704 (2022).
29. M. Kuroki, *Journal of Economic Education*, **54**, 4, 364-378 (2023).
30. S.V. Bochkarev, E.S. Obukhov, *Fundamental Research*, 11-3, 476-481 (2016).
31. A.S. Katasev, *Cybernetics and programming*, 6, 110-122 (2018).
32. A.I. Barinov, D.V. Kataseva, A.S. Katasev, *Herald of Technological University*, **23**, 10, 64-67 (2020).
33. L.A. Demidova, M.M. Egin, Yu.S. Sokolova, *Cloud of Science*, **4**, 4, 572-592 (2017).
34. A. Gregory, T. Jones, *Journal of Southwestern Anthropology and History*, **88**, 1, 144-146 (2022).
35. O.A. Pynova, *Scientific and Technical Bulletin of Povolzhya*, 11, 254-256 (2023).
36. Ch. Porter, *Southwestern Historical Quarterly*, **125**, 4, 510-511 (2022).
37. H.P. Daly, *Western Historical Quarterly*, **54**, 1, 93-98 (2023).
38. J. Bess, *Journal of Anthropological Research*, **78**, 2, 244-246 (2022).
39. A. Velu, M. Thangavelu, *Computers, Materials and Continua*, **71**, 1, 457-471 (2022).
40. Ch. Azad, B. Bhushan, R. Sharma, A. Shankar, *Multimedia Systems*, **28**, 4, 1289-1307 (2022).
41. F. Mustofa, A.N. Safriandono, *Journal of Computing Theories and Applications*, **1**, 1, 41-48 (2023).
42. B.S. Bahnam, S.A. Dawwod, *International Journal of Artificial Intelligence*, **11**, 3, 1164-1175 (2022).
43. D.A. Pustokhin, I.V. Pustokhina, M. Ilayaraja, *Studies in Fuzziness and Soft Computing*, **413**, 41-55 (2022).

© **А. С. Катасёв** – д-р техн. наук, профессор кафедры систем информационной безопасности КНИТУ-КАИ, профессор кафедры цифровых систем и моделей КГЭУ, e-mail: askatasev@kai.ru; **Д. В. Катасёва** – канд. техн. наук, доцент кафедры систем информационной безопасности КНИТУ-КАИ, e-mail: dvkataseva@kai.ru; **Д. З. Валиева** – магистрант кафедры систем информационной безопасности КНИТУ-КАИ, главный специалист проектного сектора Центра разработки и сопровождения информационных систем ГБУ «Безопасность дорожного движения», e-mail: dvalieva99@mail.ru; **Г. Л. Дегтярёв** – д-р техн. наук, профессор кафедры автоматизации и управления КНИТУ-КАИ, e-mail: gldegtyarev@mail.ru.

© **A. S. Katasev** – Dr.Tech.Sc., Professor of Information Security Systems Department, KNRTU named after A.N. Tupolev, Professor of Digital Systems and Models Department, KGEU, e-mail: askatasev@kai.ru; **D. V. Kataseva** – PhD, Associate Professor of Information Security Systems Department, KNRTU named after A.N. Tupolev, e-mail: dvkataseva@kai.ru; **D. Z. Valieva** – Master student of Information Security Systems Department, KNRTU named after A.N. Tupolev, Chief specialist of the project sector of the Center for development and maintenance of information systems, Road Safety State Company, e-mail: dvalieva99@mail.ru; **G. L. Degtyarev** – Dr.Tech.Sc., Professor of Automation and Control Department, KNRTU named after A.N. Tupolev, e-mail: gldegtyarev@mail.ru.