

## ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

УДК 004.93

DOI 10.55421/3034-4689\_2026\_29\_5\_87

Д. В. Катасёва, М. Д. Родионов

## НЕЙРОСЕТЕВАЯ МОДЕЛЬ КЛАССИФИКАЦИИ АСТРОНОМИЧЕСКИХ ОБЪЕКТОВ

*Ключевые слова:* классификация астрономических объектов, нейросетевое моделирование, многослойный перцептрон, фотометрические данные, SDSS, цветовые индексы, машинное обучение.

Статья посвящена решению задачи автоматической классификации астрономических объектов (звезд, галактик и квазаров) на основе фотометрических данных с использованием нейросетевой модели. Актуальность работы обусловлена стремительным ростом объемов астрономических наблюдений, делающим ручную классификацию практически невыполнимой, а также развитием методов машинного и глубокого обучения, открывающих новые возможности для автоматизации анализа астрономических каталогов. Задача осложняется высокой вариативностью фотометрических признаков и частичным перекрытием характеристик между классами объектов. В качестве источника данных использован общедоступный датасет Stellar Classification Dataset с платформы Kaggle. Данные получены из обзора Sloan Digital Sky Survey и представляют собой таблицу из 100 000 объектов, каждый из которых описывается набором физических и наблюдательных параметров. Целевой признак (метка класса) принимает одно из трех значений. Для построения нейросетевой модели классификации использован язык программирования Python, а также библиотеки и фреймворки Keras, TensorFlow, Scikit-learn, NumPy, Pandas и Matplotlib. Нейросетевая модель выполнена в виде многослойного перцептрона, включающего три скрытых слоя с функцией активации ReLU и механизмом Dropout для предотвращения переобучения. Признаковое пространство дополнено цветовыми индексами, позволяющими модели учитывать форму спектра объекта. Построенная модель достигла точности 97% на валидационной выборке данных. В течение всего процесса ее обучения наблюдалась близость значений потерь на обучающей и валидационной выборках данных. Это свидетельствует об отсутствии выраженного переобучения, что подтверждается стабилизацией обеих кривых на уровне около 0,1 к концу тридцатой эпохи обучения. После построения нейросетевой модели проведен анализ ее эффективности. Для этого построена матрица ошибок классификации, а также для каждого класса рассчитаны значения метрик accuracy, precision, recall и F1-score. Анализ матрицы ошибок и указанных метрик выявил характерные трудности при разграничении галактик и квазаров, обусловленные перекрытием их цветовых индексов, и обозначил направления для дальнейшего совершенствования модели: расширение признакового пространства, применение более сложных нейросетевых архитектур, адаптация модели для обработки других наборов данных, а также применение методов интерпретируемости моделей. Практическая значимость работы состоит в возможности применения разработанного решения для автоматизированной обработки больших каталогов астрономических наблюдений.

D. V. Kataseva, M. D. Rodionov

## NEURAL NETWORK MODEL FOR CLASSIFICATION OF ASTRONOMICAL OBJECTS

*Keywords:* astronomical object classification, neural network modeling, multilayer perceptron, photometric data, color indices, SDSS, machine learning.

This article explores the problem of automatically classifying astronomical objects (stars, galaxies, and quasars) based on photometric data using a neural network model. The relevance of this work stems from the rapid growth of astronomical observations, making manual classification virtually impossible, and the development of machine and deep learning methods, which offer new opportunities for automating the analysis of astronomical catalogs. The task is complicated by the high variability of photometric features and the partial overlap of characteristics between object classes. The publicly available Stellar Classification Dataset from the Kaggle platform was used as the data source. The data, obtained from the Sloan Digital Sky Survey, is a table of 100,000 objects, each described by a set of physical and observational parameters. The target feature (class label) takes one of three values. The Python programming language, as well as the Keras, TensorFlow, Scikit-learn, NumPy, Pandas, and Matplotlib libraries and frameworks, were used to build the neural network classification model. The neural network model is implemented as a multilayer perceptron, comprising three hidden layers with a ReLU activation function and a dropout mechanism to prevent overfitting. The feature space is supplemented with color indices, allowing the model to account for the shape of the object's spectrum. The constructed model achieved 97% accuracy on the validation data set. Throughout the training process, the loss values for the training and validation data sets were close. This indicates the absence of significant overfitting, as confirmed by the stabilization of both curves at approximately 0.1 by the end of the 30th training epoch. After constructing the neural network model, its effectiveness was analyzed. For this purpose, a classification error matrix was constructed, and the accuracy, precision, recall, and F1-score metrics were calculated for each class. An analysis of the error matrix and the aforementioned metrics revealed inherent difficulties in distinguishing galaxies from quasars due to overlapping color indices. This analysis also identified areas for further model improvement: expanding the feature space, applying more complex neural network architectures, adapting the model to process other datasets, and applying model interpretability methods. The practical significance of this

*work lies in the potential application of the developed solution for automated processing of large catalogs of astronomical observations.*

## Введение

Современные методы машинного обучения [1-3] и глубокого обучения [4-6] позволяют решать задачи распознавания и классификации объектов на основе многомерных признаков. Задача автоматической классификации звезд, галактик и квазаров имеет фундаментальное значение для построения космологических моделей, изучения структуры Вселенной и анализа процессов звездообразования [7].

Фотометрические данные, получаемые в системе фильтров  $u, g, r, i, z$ , содержат информацию о распределении энергии излучения объектов в различных диапазонах длин волн. На основе этих величин формируются цветовые индексы, позволяющие выявлять различия в температуре, возрасте и спектральных особенностях объектов. Однако границы между классами могут быть размыты, а влияние красного смещения и наблюдательных погрешностей усложняет задачу классификации. Актуальность исследований в данном направлении подтверждается активным применением нейросетевых методов в задачах анализа больших астрономических данных [8, 9]. Эффективность решений напрямую зависит от качества подготовки выборки, выбора признаков, архитектуры модели и методов оптимизации [10, 11].

Задача классификации астрономических объектов по фотометрическим данным является одной из ключевых в современной вычислительной астрофизике. Достижения в области глубокого обучения позволили существенно повысить точность автоматических систем распознавания, что открывает возможности их практического применения для предварительной обработки каталогов наблюдений и поддержки астрономических исследований.

Для классификации астрономических объектов традиционно используются следующие группы методов: статистические [12, 13], нейросетевые [14-16], а также методы машинного обучения [17, 18]. При этом задача классификации осложняется высокой вариабельностью фотометрических данных [19, 20]. Звезды характеризуются спектрами, близкими к излучению абсолютно черного тела, галактики представляют собой совокупность излучения множества звездных популяций, а квазары обладают выраженными эмиссионными линиями и значительными значениями красного смещения. Несмотря на различия в физической природе объектов, их фотометрические параметры могут принимать близкие значения, что требует применения методов, способных учитывать многомерные взаимосвязи [21-23].

В работе для решения поставленной задачи применен подход на основе многослойного перцептрона с тремя выходными классами [24, 25]. В качестве исходных данных использованы фотометрические величины  $u, g, r, i, z$ , значение красного смещения и сформированные цветовые индексы. Решение задачи потребовало выполнения следующих этапов:

- 1) выбор и подготовка исходных данных;
- 2) выбор библиотек и архитектуры модели;

3) обучение и оценка качества модели с использованием метрик классификации.

Рассмотрим эти этапы более подробно.

## Выбор и подготовка данных для построения нейросетевой модели

Для решения задачи классификации астрономических объектов выбран общедоступный набор Stellar Classification Dataset [26] с платформы Kaggle [27]. Набор содержит фотометрические наблюдения трех классов объектов: звезд (STAR), галактик (GALAXY) и квазаров (QSO). Данные получены из обзора Sloan Digital Sky Survey (SDSS) [28] и представляют собой таблицу из 100 000 объектов, каждый из которых описывается набором физических и наблюдательных параметров. Целевой признак (метка класса) принимает одно из трех значений.

Для обучения модели из всего набора параметров отобраны физически значимые признаки: пять фотометрических величин ( $u, g, r, i, z$ ), соответствующих яркости объекта в диапазонах от ближнего ультрафиолета до дальнего инфракрасного, а также значение красного смещения (redshift), характеризующее удаленность объекта от наблюдателя.

В ходе подготовки данных был выявлен ряд проблем и предложены пути их решения:

- 1) поскольку величины  $u, g, r, i, z$  являются ключевыми для описания спектральных свойств объекта, строки с отсутствующими значениями в этих столбцах полностью удалялись из выборки;
- 2) в случае пропусков красного смещения применялось их заполнение медианными значениями.

## Выбор библиотек и архитектуры нейросетевой модели

Для построения нейросетевой модели классификации использован язык программирования Python [29]. Для реализации использованы следующие библиотеки и фреймворки [30-32]: Keras, TensorFlow, Scikit-learn, NumPy, Pandas и Matplotlib.

В работе реализована архитектура многослойного перцептрона [33] с тремя скрытыми слоями с функцией активации ReLU и механизмом Dropout для предотвращения переобучения. Эта архитектура выбрана в связи со спецификой решаемой задачи: входные данные представлены в виде таблицы числовых признаков, где каждый объект характеризуется вектором фотометрических величин и цветовых индексов, а не изображением или последовательностью. В таких условиях сверточные [34, 35] или рекуррентные сети [36, 37] не дают явных преимуществ, тогда как перцептрон способен эффективно выявлять нелинейные зависимости в данных.

## Обучение и оценка качества нейросетевой модели

Обучение модели проводилось с использованием оптимизатора Adam. Актуальность его применения подтверждается современными исследованиями: оптимизатор Adam обеспечивает автоматическую

адаптацию скорости обучения для каждого параметра сети, что ускоряет сходимость и повышает стабильность процесса обучения по сравнению с классическим градиентным спуском.

Процесс обучения сопровождался вычислением выходных значений модели, функции потерь, обратным распространением ошибки и настройкой гиперпараметров. После завершения каждого прохода проводилась оценка модели на валидационной выборке. Значения функции потерь и точности на обучающих и валидационных данных сохранялись в истории обучения для последующего анализа.

На рисунке 1 представлены графики изменения значений функции потерь на обучающей и валидационной выборках в процессе обучения модели.




Рис. 1 – Графики изменения значений функции потерь в процессе обучения модели

Fig. 1 – Graphs of changes in the loss function during model training

На рисунке 2 представлены графики изменения точности нейросетевой модели на обучающей и валидационной выборках.




Рис. 2 – Графики изменения точности модели в процессе обучения

Fig. 2 – Graphs of model accuracy changes during training

В результате обучения модель достигла точности 97% на валидационной выборке. Близость значений потерь на обучающей и валидационной выборках на протяжении всего процесса обучения свидетельствует об отсутствии выраженного переобучения,

что подтверждается стабилизацией обеих кривых на уровне около 0,1 к концу тридцатой эпохи.

В исследовании проведен анализ эффективности нейросетевой модели. Для этого построена матрица ошибок классификации [38], а также для каждого класса рассчитаны значения следующих метрик [39]: accuracy, precision, recall и F1-score.

В таблице 1 представлены результаты классификации обученной модели.

Таблица 1 – Матрица ошибок классификации

Table 1 – Classification confusion matrix

Результат классификации на основе нейросетевой модели	Фактический класс		
	STAR	GALAXY	QSO
STAR	11579	149	161
GALAXY	235	3554	3
QSO	2	0	4317

Наибольшее число ошибочных классификаций приходится на разграничение звезд и галактик: 149 звезд были ошибочно классифицированы как галактики, а 235 галактик – как звезды. Это объясняется тем, что отдельные звезды с нетипичными цветовыми индексами занимают области признакового пространства, близкие к компактным галактикам. Ошибки между звездами и квазарами встречаются значительно реже: 161 звезда была отнесена к квазарам, тогда как 2 квазара ошибочно классифицированы как звезды. Наименьшее перекрытие наблюдается между галактиками и квазарами – всего 3 галактики были отнесены к классу квазаров и ни один квазар не был ошибочно определен как галактика.

На основе матрицы ошибок сформирован отчет о классификации с расчетом соответствующих метрик (см. табл. 2).

Таблица 2 – Отчет о классификации

Table 2 – Classification report

Классы объектов	Метрики качества классификации		
	precision	recall	F1-score
STAR	0,98	0,97	0,98
GALAXY	0,96	0,94	0,95
QSO	0,96	1	0,98

Анализ значений метрик выявил эффективность модели для классификации всех типов объектов. Наилучший результат показал класс квазаров: при значении recall=1 модель распознала практически все объекты этого класса в валидационной выборке, а F1-score составил 0.98. Для звезд получены значения precision=0.98, recall=0.97, F1-score=0.98. Для галактик precision=0.96, recall=0.94, F1-score=0.95, что объясняется большей вариативностью их характеристик по сравнению с другими классами.

### Заключение

В результате исследования разработана и обучена нейросетевая модель классификации астрономических объектов на основе архитектуры многослой-

ного персептрона, способная с высокой точностью разграничивать звезды, галактики и квазары по фотометрическим данным. Дополнение исходного признакового пространства цветовыми индексами и применение стандартизации позволили достичь точности 97% на валидационной выборке, что подтверждает эффективность разработанного подхода для задач классификации астрофизических данных.

Детальный анализ результатов с применением матрицы ошибок и метрик precision, recall, F1-score подтвердил, что модель успешно улавливает ключевые спектральные различия между классами объектов. Разработанное решение может быть использовано в качестве инструмента для автоматической обработки данных астрономических наблюдений и сокращения времени анализа больших каталогов объектов. Перспективы развития исследования связаны с расширением признакового пространства за счет включения спектроскопических параметров, применения более сложных нейросетевых архитектур [40], а также адаптацией модели для обработки других наборов данных. Отдельным актуальным направлением исследований является применение методов интерпретируемости моделей.

### Литература

1. S. Wang, B. Chen, *Informatics. Economics. Management*, **2**, 4, 134-144 (2023).
2. Р.И. Юсупова, Р.С. Зарипова, М.Г. Нуриев, *Казанская наука*. 2025. № 2. С. 201-203.
3. Д.В. Катаева, Д.Д. Лосева, *Вестник Технологического университета*, **25**, 1, 77-80 (2022).
4. Р.Н. Минниханов, А.С. Катаев, Д.В. Катаева, В. Скибин, *Вестник Технологического университета*, **27**, 11, 199-205 (2024).
5. К.А. Матвеева, Р.Н. Минниханов, А.С. Катаев, *Вестник Технологического университета*, **27**, 1, 76-80 (2024).
6. В.А. Лохвицкий, Е.Л. Яковлев, И.В. Бушев, *Интеллектуальные технологии на транспорте*, **4** (44), 89-98 (2025).
7. А.С. Ходжаев, И.И. Зинченко, *Астрофизический бюллетень*, **80**, 1, 145-167 (2025).
8. В.А. Голов, Д.А. Петрусевич, *Russian Technological Journal*, **9**, 3 (41), 66-77 (2021).
9. Г.А. Галазутдинов, *Астрофизический бюллетень*, **77**, 4, 579-590 (2022).
10. Л. Тань, С.В. Новикова, *Вестник Казанского государственного энергетического университета*, **14**, 3, 114-125 (2022).
11. К.А. Омарова, А.У. Ахмадов, О.А. Пырнова, *Проблемы современного педагогического образования*, **85-4**, 312-317 (2024).
12. М.Г. Нуриев, Е.С. Белашова, К.А. Барабаш, *Программные системы и вычислительные методы*, **1**, 1 (2023).
13. К.А. Сапрыкин, *Инновации и инвестиции*, **11**, 322-325 (2023).
14. Д.А. Набиуллин, В.В. Кононова, С.В. Новикова, *Вестник Технологического университета*, **24**, 6, 103-107 (2021).
15. А.С. Катаев, Д.В. Катаева, Ю.Н. Смирнов, Л.Н. Кунафина, *Вестник Технологического университета*, **27**, 10, 101-105 (2024).
16. А.И. Сабиров, Р.Н. Минниханов, А.С. Катаев, Р.И. Мустафин, *Вестник Технологического университета*, **27**, 1, 87-91 (2024).
17. A. Bobokhonov, L. Khuramov, A. Rashidov, *Проблемы информатики*, **3** (68), 52-71 (2025).
18. K. Lathong, K. Wisaeng, *International Journal for Computational Civil and Structural Engineering*, **20**, 3, 69-83 (2024).
19. А.Н. Григорьев, А.И. Алтухов, Д.С. Коршунов, *Научно-технический вестник информационных технологий, механики и оптики*, **21**, 3, 311-319 (2021).
20. A.N. Tarasenkoy, *INASAN Science Reports*, **9**, 3, 89-92 (2024).
21. О.А. Пырнова, Р.С. Зарипова, *Информационные технологии в строительных, социальных и экономических системах*, **1** (15), 82-84 (2019).
22. М.П. Шлеймович, М.В. Дагаева, А.С. Катаев, С.А. Ляшева, М.В. Медведев, *Компьютерные исследования и моделирование*, **10**, 3, 369-376 (2018).
23. М.В. Дагаева, Д.В. Катаева, А.С. Катаев, *Информация и безопасность*, **21**, 4, 540-545 (2018).
24. В.С. Тормозов, К.А. Василенко, А.Л. Золкин, *Программные продукты и системы*, **2**, 343-348 (2020).
25. М.И. Черных, С.А. Победа, Д.А. Жукалин, *Вестник Воронежского государственного университета. Серия: Физика. Математика*, **2**, 42-49 (2021).
26. kaggle.com: сайт. – URL: <https://www.kaggle.com/datasets/fedesoriano/stellar-classification-dataset-sdss17> (дата обращения: 25.03.2026).
27. A.R. Raju, T. Maddileti, R. Srinivas, K. Saikumar, *International Journal of Integrated Engineering*, **14**, 7 (2022).
28. Д.Х. Беков, Т.А. Ахуннов, О.А. Бурхонов, Н.Р. Алимова, *Астрофизический бюллетень*, **79**, 1, 16-25 (2024).
29. И.Ю. Пикалов, *Вестник МГПУ. Серия: Информатика и информатизация образования*, **2** (68), 48-61 (2024).
30. О.Л. Ибряева, Д.К. Лебедев, *Автоматизация в промышленности*, **8**, 55-58 (2023).
31. Н.А. Пастухов, *Автоматизированное проектирование в машиностроении*, **17**, 87-89 (2024).
32. Б.Х. Нургалиев, А.С. Катаев, *Вестник Технологического университета*, **25**, 1, 61-64 (2022).
33. Е.Ю. Шмалько, Ю.А. Румянцев, Р.Р. Байназаров, К.Л. Ямшанов, *Информатика и автоматизация*, **20**, 6, 1254-1278 (2021).
34. А.С. Катаев, Д.В. Катаева, Ю.Н. Смирнов, В.Л. Васильев, *Вестник Технологического университета*, **27**, 9, 115-119 (2024).
35. А.С. Катаев, Д.В. Катаева, Ю.Н. Смирнов, Н.И. Фаттахов, *Вестник Технологического университета*, **27**, 10, 112-119 (2024).
36. Д.М. Оболенский, В.И. Шевченко, О.В. Ченгарь, Е.Н. Машенко, *Экономика. Информатика*, **48**, 1, 100-115 (2021).
37. I.A. Brokarev, M.P. Farkhadov, S.V. Vaskovskii, *Tomsk State University Journal of Control and Computer Science.*, **55**, 11-17 (2021).
38. В.В. Старовойтов, Ю.И. Голуб, *Информатика*, **18**, 1, 61-71 (2021).
39. В.А. Буланов, О.Е. Фомичева, *Приборы и системы. Управление, контроль, диагностика*, **3**, 33-37 (2020).
40. Л.Ю. Емалетдинова, А.С. Катаев, М.А. Назаров, *Инженерный вестник Дона*, **7** (103), 71-80 (2023).

### References

1. S. Wang, B. Chen, *Informatics. Economics. Management*, **2**, 4, 134-144 (2023).
2. R.I. Yusupova, R.S. Zaripova, M.G. Nuriev, *Kazan science*. 2025. № 2. С. 201-203.
3. D.V. Kataseva, D.D. Loseva, *Herald of Technological University*, **25**, 1, 77-80 (2022).
4. R.N. Minnikhanov, A.S. Katasev, D.V. Katasyova, V. Skibin, *Herald of Technological University*, **27 Bulletin of the**, **11**, 199-205 (2024).

5. K.A. Matveeva, R.N. Minnikhanov, A.S. Katasev, *Herald of Technological University*, **27**, 1, 76-80 (2024).
6. V.A. Likhvitsky, E.L. Yakovlev, I.V. Bushev, *Intelligent Technologies in Transport*, 4 (44), 89-98 (2025).
7. A.S. Khodjaev, I.I. Zinchenko, *Astrophysical Bulletin*, **80**, 1, 145-167 (2025).
8. V.A. Golov, D.A. Petrusevich, *Russian Technological Journal*, **9**, 3 (41), 66-77 (2021).
9. G.A. Galazutdinov, *Astrophysical Bulletin*, **77**, 4, 579-590 (2022).
10. L. Tan, S.V. Novikova, *Bulletin of the Kazan State Power Engineering University*, **14**, 3, 114-125 (2022).
11. K.A. Omarova, A.U. Akhmadov, O.A. Purnova, *Problems of modern pedagogical education*, 85-4, 312-317 (2024).
12. M.G. Nuriev, E.S. Belashova, K.A. Barabash, *Software systems and computational methods*, **1**, 1 (2023).
13. K.A. Saprykin, *Innovations and Investments*, 11, 322-325 (2023).
14. YES. Nabiullin, V.V. Kononova, S.V. Novikova, *Herald of Technological University*, **24**, 6, 103-107 (2021).
15. A.S. Katasev, D.V. Kataseva, Yu.N. Smirnov, L.N. Kunafina, *Herald of Technological University*, **27**, 10, 101-105 (2024).
16. A.I. Sabirov, R.N. Minnikhanov, A.S. Katasev, R.I. Mustafin, *Herald of Technological University*, **27**, 1, 87-91 (2024).
17. A. Bobokhonov, L. Khuramov, A. Rashidov, *Problems of computer science*, 3 (68), 52-71 (2025).
18. K. Lathong, K. Wisaeng, *International Journal for Computational Civil and Structural Engineering*, **20**, 3, 69-83 (2024).
19. A.N. Grigoriev, A.I. Altukhov, D.S. Korshunov, *Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics*, **21**, 3, 311-319 (2021).
20. A.N. Tarasenkov, *INASAN Science Reports*, **9**, 3, 89-92 (2024).
21. O.A. Purnova, R.S. Zaripova, *Information technologies in construction, social and economic systems*, 1 (15), 82-84 (2019).
22. M.P. Shleimovich, M.V. Dagaeva, A.S. Katasev, S.A. Lyasheva, M.V. Medvedev, *Computer Research and Modeling*, **10**, 3, 369-376 (2018).
23. M.V. Dagaeva, D.V. Kataseva, A.S. Katasev, *Information and Security*, **21**, 4, 540-545 (2018).
24. V.S. Tormozov, K.A. Vasilenko, A.L. Zolkin, *Software products and systems*, 2, 343-348 (2020).
25. M.I. Chernykh, S.A. Pobeda, D.A. Zhukalin, *Bulletin of Voronezh State University. Series: Physics. Mathematics*, 2, 42-49 (2021).
26. kaggle.com: website. – URL: <https://www.kaggle.com/datasets/fedoriano/stellar-classification-dataset-sdss17> (date of access: 25.03.2026).
27. A.R. Raju, T. Maddileti, R. Srinivas, K. Saikumar, *International Journal of Integrated Engineering*, **14**, 7 (2022).
28. D.H. Bekov, T.A. Akhunov, O.A. Burkhonov, N.R. Alimova, *Astrophysical Bulletin*, **79**, 1, 16-25 (2024).
29. I.Yu. Pikalov, *Bulletin of Moscow State Pedagogical Univ. Series: Informatics and Informatization of Education*, 2 (68), 48-61 (2024).
30. O.L. Ibrayeva, D.K. Lebedev, *Automation in Industry*, 8, 55-58 (2023).
31. N.A. Pastukhov, *Computer-aided design in mechanical engineering*, 17, 87-89 (2024).
32. B.H. Nurgaliev, A.S. Katasev, *Herald of Technological University*, **25**, 1, 61-64 (2022).
33. E.Yu. Shmalko, Yu.A. Rumyantsev, R.R. Baynazarov, K.L. Yamshanov, *Computer Science and Automation*, **20**, 6, 1254-1278 (2021).
34. A.S. Katasev, D.V. Kataseva, Yu.N. Smirnov, V.L. Vasiliev, *Herald of Technological University*, **27**, 9, 115-119 (2024).
35. A.S. Katasev, D.V. Kataseva, Yu.N. Smirnov, N.I. Fattakhov, *Herald of Technological University*, **27**, 10, 112-119 (2024).
36. D.M. Obolensky, V.I. Shevchenko, O.V. Chengar, E.N. Mashchenko, *Economics. Computer Science*, **48**, 1, 100-115 (2021).
37. I.A. Brokarev, M.P. Farkhadov, S.V. Vaskovskii, *Tomsk State University Journal of Control and Computer Science.*, 55, 11-17 (2021).
38. V.V. Starovoytov, Yu.I. Golub, *Computer Science*, **18**, 1, 61-71 (2021).
39. V.A. Bulanov, O.E. Fomicheva, *Devices and systems. Management, control, diagnostics*, 3, 33-37 (2020).
40. L.Yu. Emaletdinova, A.S. Katasev, M.A. Nazarov, *Engineering Herald of the Don*, 7 (103), 71-80 (2023).

© **Д. В. Катасёва** – канд. техн. наук, доцент кафедры Систем информационной безопасности (СИБ), Казанский национальный исследовательский технический университет имени А.Н. Туполева (КНИТУ им. А.Н. Туполева), Казань, Россия, DVKataseva@kai.ru; **М. Д. Родионов** – магистрант кафедры СИБ, КНИТУ им. А.Н. Туполева, misha25025.su@gmail.com.

© **D. V. Kataseva** – PhD (Technical Sci.), Associate Professor of Information Security Systems (ISS) Department, Kazan National Research Technical University named after A.N. Tupolev, KNRTU named after A.N. Tupolev, Kazan, Russia, DVKataseva@kai.ru; **M. D. Rodionov** – Master Student of the ISS department, KNRTU named after A.N. Tupolev, misha25025.su@gmail.com.

Дата поступления рукописи в редакцию – 27.03.26.

Дата принятия рукописи в печать – 08.04.26.