

## ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

УДК 004.93

DOI 10.55421/3034-4689\_2026\_29\_3\_130

Д. В. Катасёва, А. А. Алексеева

### НЕЙРОСЕТЕВОЙ КЛАССИФИКАТОР ДЛЯ ОПРЕДЕЛЕНИЯ АВТОРСТВА ПРОИЗВЕДЕНИЙ ХУДОЖНИКОВ-ИМПРЕССИОНИСТОВ

*Ключевые слова:* классификация изображений, определение авторства, импрессионизм, нейросетевое моделирование, сверточная нейронная сеть, ResNet-50.

Статья посвящена решению задачи определения авторства произведений художников-импрессионистов по цифровым изображениям на основе построения и исследования нейросетевой сверточной модели. Актуальность выполненной работы обусловлена не только необходимостью цифровизации объектов культурного наследия, но и стремительным развитием генеративных нейронных сетей, которые ставят новые задачи по различению графического контента, созданного человеком и искусственным интеллектом. Импрессионизм, как одно из ключевых направлений в живописи, характеризуется уникальными, но трудно формализуемыми признаками. Определение авторства произведения, когда все художники работают в рамках одного стиля, является очень сложной задачей, поскольку различия в технике мазка автора, цветовой палитре и композиции могут быть очень тонкими и незначительными. Поэтому для решения этой задачи целесообразно использовать современные методы искусственного интеллекта, основанные на глубоком обучении. В работе применен подход на основе сверточных нейронных сетей с использованием технологии трансферного обучения. Для его реализации выполнены следующие основные этапы: получение и подготовка данных для анализа, выбор библиотек и архитектуры для построения нейросетевой модели, обучение модели, оценка результатов ее работы. Для реализации первого этапа использован общедоступный набор данных *Impressionist Classifier Data*, полученный с платформы *Kaggle* и содержащий работы десяти известных художников-импрессионистов. Общее число изображений для классификации составило 4978, из которых обучающая выборка содержала 3990, а валидационная – 988 изображений. Для построения сверточной нейросетевой модели использован язык программирования *Python*, а также следующие библиотеки и фреймворки: *PyTorch*, *torchvision*, *NumPy*, *Pandas*, *Matplotlib* и другие. Рассмотрена и реализована архитектура сверточной нейронной сети *ResNet-50*, предобученная на базе данных *ImageNet*, которая была адаптирована для решения задачи классификации для 10 классов. Применена стратегия обучения с заморозкой слоев и последующей тонкой настройкой. Построенная (дообученная) модель продемонстрировала высокую эффективность, достигнув точности 86,06% на валидационной выборке данных. Проведен анализ качества классификации модели с использованием матрицы ошибок, ROC-кривых и других метрик (*accuracy*, *Top-3 accuracy*, *precision*, *recall* и *F1-score*). Выявлены проблемы с классификацией стилистически близких художников, что указало на необходимость дополнительной балансировки выборки и применения специализированных методов аугментации. Намечены направления перспективных исследований.

D. V. Kataseva, A. A. Alekseeva

### A NEURAL NETWORK CLASSIFIER FOR IDENTIFYING THE AUTHORSHIP OF WORKS CREATED BY IMPRESSIONIST ARTISTS

*Keywords:* image classification, authorship determination, impressionism, neural network modeling, convolutional neural network, ResNet-50.

This article addresses the problem of identifying the authorship of works by impressionist artists based on digital images, using the construction and analysis of a convolutional neural network model. The relevance of this work stems not only from the need to digitalize cultural heritage sites but also from the rapid development of generative neural networks, which pose new challenges in distinguishing graphic content created by humans and artificial intelligence. Impressionism, as one of the key artistic movements, is characterized by unique, yet difficult to formalize, features. Identifying the authorship of a work when all artists work within the same style is a very complex task, as differences in the author's brushstroke technique, color palette, and composition can be very subtle and insignificant. Therefore, modern artificial intelligence methods based on deep learning are appropriate for solving this problem. This paper employs an approach based on convolutional neural networks using transfer learning technology. The following main stages were completed: obtaining and preparing data for analysis, selecting libraries and architecture for constructing a neural network model, training the model, and evaluating its performance. The first stage was implemented using the publicly available *Impressionist Classifier Dataset*, obtained from the *Kaggle* platform and containing works by ten famous impressionist artists. The total number of images for classification was 4,978, of which the training set contained 3,990 images, and the validation set contained 988 images. The *Python* programming language, as well as the following libraries and frameworks, were used to build the convolutional neural network model: *PyTorch*, *torchvision*, *NumPy*, *Pandas*, *Matplotlib*, and others. The architecture of the *ResNet-50* convolutional neural network, pretrained on the *ImageNet* database, was considered and implemented, adapted to solve the classification problem for 10 classes. A training strategy with frozen layers and subsequent fine-tuning was applied. The constructed (retrained) model

*demonstrated high efficiency, achieving 86.06% accuracy on the validation data set. An analysis of the model's classification quality was conducted using a confusion matrix, ROC curves, and other metrics (accuracy, Top-3 accuracy, precision, recall, and F1 score). Issues with classifying stylistically similar artists were identified, indicating the need for additional sample balancing and the use of specialized augmentation methods. Directions for future research are outlined.*

## Введение

В настоящее время с развитием технологий искусственного интеллекта [1, 2] и машинного обучения [3-5], в частности, с появлением генеративно-состязательных моделей [6], стала возможной автоматизация создания визуального контента. Генерируемые изображения с высокой точностью повторяют авторские произведения (картины) и визуально неотличимы от них [7]. В этих условиях задачи автоматической атрибуции, каталогизации и стилистического анализа произведений искусства приобретают большое значение, распространяясь не только на определение авторских прав, но и на различные работ человека и искусственного интеллекта.

Импрессионизм, как одно из ключевых направлений живописи конца XIX века, характеризуется уникальными, но при этом поддающимися формализации признаками. Определение авторства картины, когда все художники работают в рамках одного стиля, является сложной задачей, поскольку стилистические различия трудно различимы. Актуальность исследований в этом направлении подтверждается интересом научного сообщества не только к задачам классификации, но и к смежным областям, таким как нейросетевая стилизация [8, 9]. Точность и универсальность таких решений напрямую зависят от качества обучающих данных, архитектуры моделей и методов обработки изображений [10].

### Анализ предметной области и постановка решаемой задачи

Задача классификации произведений искусства по автору является актуальной в области компьютерного зрения и цифровых гуманитарных наук [11]. Современные достижения в области глубокого обучения [12] позволили существенно повысить точность таких систем, что открыло широкие перспективы для их практического использования в качестве помощников для искусствоведов, музейных работников и кураторов для предварительной атрибуции и каталогизации работ художников.

Существующие подходы к решению этой задачи можно условно разделить на три группы: традиционные методы искусствоведческого анализа [13], методы, основанные на ручных признаках [14], и современные методы с использованием сверточных нейронных сетей [15-17]. Сверточные нейронные сети, в отличие от других методов, позволяют автоматически извлекать наиболее значимые признаки из изображений, не требуя ручного вмешательства в процесс формирования признаков. Благодаря своей многослойной архитектуре, такие сети способны распознавать как низкоуровневые текстуры (например, фактуру мазка кисти), так и высокоуровневые композиционные особенности.

Для классификации авторства внутри одного стиля с высокой внутренней вариативностью каждого художника и тематическими пересечениями, необходимо применение современных методов глубокого обучения [18]. Такие методы позволяют решать не только задачи классификации, но и обратную задачу – стилизацию изображений [19].

Так, в работе [20] на основе генеративно-состязательных сетей была описана система для стилизации изображений в манере Винсента Ван Гога, Клода Моне и Анри Матисса. Авторы подчеркивают, что для успешной стилизации критически важны такие характеристики, как узнаваемость стиля и жанровое разнообразие работ художника. При этом существующие методы классификации демонстрируют ограниченную точность. Например, в одной из работ на аналогичном наборе данных с использованием архитектуры MobileNetV2 [21] была достигнута точность классификации в пределах 70%. Этот результат указывает на необходимость применения более глубоких и современных нейросетевых архитектур [22-24], а также оптимизации методов предобработки и обучения.

В работе для решения этой задачи применен подход на основе сверточных нейронных сетей с использованием технологии трансферного обучения [25]. Для этого выполнены следующие этапы:

- 1) получение и подготовка данных для анализа;
  - 2) выбор библиотек и архитектуры для построения нейросетевой модели;
  - 3) обучение модели;
  - 4) оценка результатов ее работы.
- Рассмотрим реализацию указанных этапов.

### Получение и подготовка данных для построения нейросетевой модели

Для решения задачи определения авторства произведений художников-импрессионистов выбран общедоступный набор данных Impressionist Classifier Data с платформы Kaggle [26]. Набор содержит работы десяти известных художников: Camille Pissarro, Childe Hassam, Claude Monet, Edgar Degas, Henri Matisse, John Singer-Sargent, Paul Cezanne, Paul Gauguin, Pierre-Auguste Renoir, Vincent van Gogh. Изображения имеют различное разрешение, ориентацию и цветовую палитру. Набор разделен на обучающую и валидационную выборки, организованные по папкам для каждого художника. Обучающий набор содержит по 399 изображений каждого художника, валидационный – по 99. Общее число изображений, хранящихся в файлах в формате JPEG, составляет 4978. Из них обучающая выборка содержит 3990 изображений, а валидационная – 988.

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

- 1) разная размерность изображений (решение: все изображения масштабированы до размера

224×224 пикселя, что соответствует требованиям архитектуры ResNet-50);

2) различное число цветовых каналов для различных изображений, например, RGBA и RGB (решение: в процессе предобработки изображения автоматически конвертируются в трехканальный формат RGB с использованием встроенных функций библиотек PyTorch и PIL).

На рисунке 1 представлен пример изображения из указанного набора данных.



Рис. 1 – Пример изображения из набора данных

Fig. 1 – Example image from the dataset

К исходным данным применялись следующие методы аугментации [27, 28]: случайное горизонтальное отражение, случайный поворот в пределах 15 градусов, а также изменение яркости, контраста и насыщенности изображений.

### Выбор библиотек и архитектуры нейросетевой модели

Для построения нейросетевой модели классификации использован язык программирования Python. Особенности работы с нейросетевыми проектами на этом языке освещены в различных источниках [29-31]. Для реализации использованы следующие библиотеки и фреймворки: PyTorch, torchvision, NumPy, Pandas, Matplotlib и Seaborn. В качестве основного фреймворка для построения и обучения нейросетевой модели выбран PyTorch, обеспечивающий динамическую компоновку вычислительного графа и удобный API для оптимизации и оценки моделей.

В данном исследовании рассмотрена и реализована архитектура сверточной нейронной сети ResNet-50 [32]. Эта модель выбрана в связи с ее популярностью, доступностью предобученных весов и широким применением в задачах анализа изображений. ResNet-50 – это глубокая архитектура сети, содержащая 50 слоев. Основная идея ResNet заключается в использовании остаточных связей, которые позволяют передавать информацию и градиенты, минуя несколько слоев, что способствует решению проблемы затухающего градиента и позволяет обучать более глубокие модели.

### Обучение нейросетевой модели

Обучение модели проводилось с использованием трансферной стратегии [33]. Ее актуальность подтверждается современными исследованиями: в условиях множества разнообразных прикладных задач построение новой модели «с нуля» для каждой из них утрачивает практический смысл, а концепция «трансфера» знаний позволяет эффективно использовать уже обученные модели [34, 35]. Для реализации концепции трансферного обучения была выбрана сверточная нейросетевая модель ResNet-50 в качестве базовой для этого исследования.

На первом этапе использовалась предобученная на базе ImageNet модель ResNet-50. Выбор именно этой архитектуры обусловлен ее высокой способностью к извлечению информативных визуальных признаков за счет остаточных соединений, позволяющих обучать более глубокие модели без деградации качества. Исходный классификационный слой сети, рассчитанный на 1000 классов ImageNet, был полностью заменен на новый последовательный блок, адаптированный под задачу классификации десяти художников. Данный блок включал линейный слой, снижающий размерность признакового вектора до 512, за которым следовала функция активации ReLU, вводящая нелинейность в преобразование. Для регуляризации и снижения риска переобучения был добавлен слой dropout с вероятностью 0.4, а завершал структуру финальный линейный слой с десятью выходами, соответствующими количеству имеющихся в наборе анализируемых данных классов художников-импрессионистов.

На начальном этапе обучения, который составил пять эпох, все слои базовой модели ResNet-50 были заморожены, и обучению подвергались только параметры нового классификационного блока. Такая стратегия позволила эффективно адаптировать модель к решению новой задачи, сохраняя ранее извлеченные признаки и снижая риск переобучения на ограниченном объеме данных. Начальная скорость обучения на этом этапе составила 0.001.

После завершения начального этапа все слои сети были разморожены для проведения тонкой настройки со сниженной скоростью обучения, равной 0.0001. Такой подход позволяет аккуратно скорректировать веса всей нейронной сети под специфические признаки изображений художников-импрессионистов, минимизируя риск разрушения ранее полученных знаний, но при этом адаптируя модель к минимальным стилистическим различиям между художниками.

Обучение нейронной сети проводилось с использованием оптимизатора Adam и функции потерь CrossEntropyLoss, что является стандартным выбором для задач многоклассовой классификации. Размер батча составил 8 изображений, что обеспечивало баланс между стабильностью градиента и эффективным использованием вычислительных ресурсов. Обучение осуществлялось в течение 40 эпох на локальной вычислительной машине.

Для каждой эпохи в процессе построения нейросетевой модели выполнялся полный проход по обучающему набору данных, включающий вычис-

ление выхода модели (результатов классификации), оценку функции потерь, обратное распространение ошибки и обновление параметров оптимизатором. После завершения прохода по обучающему набору данных проводилась оценка модели на валидационном наборе. Результаты каждой эпохи, включая значения потерь и точности на обучающих и валидационных данных, сохранялись в истории обучения для последующего анализа. Лучшие параметры модели фиксировались после каждой эпохи в случае улучшения точности на валидационном наборе.

### Анализ эффективности нейросетевой модели

В рамках выполненного исследования проведен анализ эффективности разработанной нейросетевой модели на основе архитектуры ResNet-50 для решения задачи определения авторства произведений художников-импрессионистов. Для всесторонней и объективной оценки использовались следующие метрики качества классификации, рассчитанные для обучающей и валидационной выборок [36, 37]:

- ассигасу (точность) – доля верно классифицированных образцов (примеров анализируемых изображений) из всего множества образцов в выборке;
- Топ-3 ассигасу – доля изображений, для которых правильный класс входит в три наиболее вероятных результатов классификации;
- precision (точность), recall (полнота) и F1-score (гармоническое среднее между точностью и полнотой) для каждого класса;
- матрица ошибок классификации (confusion matrix);
- ROC-кривые и значение AUC (Area Under Curve).

По результатам обучения модель достигла финальной точности 98,19% на обучающей выборке и 84,34% на валидационной. Пиковое значение точности на валидации зафиксировано на 17-й эпохе и составило 86,06%. Разница между обучающей и валидационной точностью (~13,85%) указывает на наличие некоторого переобучения, что характерно для работы с ограниченными по объему выборками. Значение Топ-3 Ассигасу, составившее 96,16%, подтверждает способность нейронной сети выделять правильный класс среди нескольких вероятных кандидатов, что особенно важно при классификации схожих по стилю художников.

На рисунках 2 и 3 представлены, соответственно, графики динамики точности и функции потерь в процессе обучения нейросетевой модели.

Анализ показал, что наилучшие значения F1-меры демонстрируют классы Matisse, Sargent и Degas, что говорит о сбалансированности результатов классификации по этим художникам. Наибольшие сложности модель испытывает при различении стилистически близких пар, таких как Cezanne/Matisse и Monet/Hassam, что подтверждается матрицей ошибок, представленной на рисунке 4.




Рис. 2 – Динамика точности в процессе обучения нейросетевой модели

Fig. 2 – Accuracy dynamics in the process of training a neural network model




Рис. 3 – Динамика функции потерь в процессе обучения нейросетевой модели

Fig. 3 – Dynamics of the loss function during the training of a neural network model




Рис. 4 – Матрица ошибок классификации

Fig. 4 – Confusion matrix

Анализ уверенности модели показал, что большинство корректных результатов классификации сосредоточено в области высокой уверенности (0.8–1.0), в то время как ошибочные классификации характеризуются более низкими значениями уверенности. Зависимость точности от уровня уверенности демонстрирует, что для изображений с уверенностью выше 0.9 точность достигает 95%. ROC-кривые, построенные для каждого класса, продемонстрировали значения AUC выше 0.9 для картин большинства художников, что свидетельствует о высокой дискриминационной и обобщающей способности разработанного классификатора.

### Заключение

В результате проведенного исследования построен классификатор на основе сети ResNet-50, способный с высокой точностью определять авторство произведений художников-импрессионистов. Применение метода трансфера обучения и стратегии тонкой настройки позволило достичь точности 86,06% на валидационной выборке, что превосходит результаты, полученные в более ранних исследованиях с использованием менее глубоких архитектур.

Анализ результатов с применением матрицы ошибок, ROC-кривых и метрик классификации подтвердил, что модель успешно улавливает ключевые стилистические особенности. Наибольшие трудности система испытывала при различении стилистически близких художников, что объясняется объективной схожестью их художественных приемов.

Разработанное решение может быть использовано в качестве вспомогательного инструмента для предварительной атрибуции и анализа картин в музейных и архивных системах. Перспективы развития этого решения связаны с расширением обучающей выборки, применением специализированных методов аугментации для проблемных классов, а также созданием веб-интерфейса для интерактивной проверки авторства. Отдельным направлением исследований является адаптация разработанного классификатора для решения более сложной задачи – дискриминации изображений [38], созданных человеком, и контента, сгенерированного нейросетевой моделью [39]. Учитывая постоянное совершенствование генеративных алгоритмов, это направление представляет собой новый вызов в области компьютерного зрения и атрибуции цифрового контента.

### Литература

1. О.А. Пырнова, Д.П. Никоноров, *Экономика и управление: проблемы, решения*, **12**, 2 (155), 118-123 (2025).
2. Р.И. Юсупова, Р.С. Зарипова, М.Г. Нуриев, *Казанская наука*, **2**, 201-203 (2025).
3. К.А. Матвеева, Р.Н. Минниханов, А.С. Катасёв, *Вестник Технологического университета*, **27**, 1, 76-80 (2024).
4. Д.А. Набиуллин, В.В. Кононова, С.В. Новикова, *Вестник Технологического университета*, **24**, 6, 103-107 (2021).
5. V.S. Sunku, V. Namboodiri, R. Mukkamala, *Problems of the Regional Energetics*, **1** (65), 1-11 (2025).
6. М.А. Нагорный, *Оригинальные исследования*, **15**, 4, 62-66 (2025).
7. Н. Dong, *Informatics and Automation*, **23**, 6, 1869-1898 (2024).
8. Н.И. Бережнов, А.А. Сирота, *Вестник Воронежского государственного университета. Серия: Системный анализ и информационные технологии*, **2**, 81-92 (2022).
9. В.А. Бурцев, Ю.С. Белов, *Электронный журнал: наука, техника и образование*, **4** (39), 35-44 (2022).
10. Л.Б. Каршакова, А.Ю. Страшнов, С.С. Нагай, А.М. Павлинов, *Бюллетень науки и практики*, **11**, 8, 162-173 (2025).
11. М.В. Shibaev, *Communications. Media. Design*, **6**, 4, 5-28 (2022).
12. А.А. Никифоров, К.В. Гудков, *Современные информационные технологии*, **41** (41), 70-74 (2025).
13. Ю.Ю. Юмашева, Д.Ю. Гук, *Историческая информатика*, **3** (41), 114-155 (2022).
14. Т.В. Portnova, *Components of Scientific and Technological Progress*, **7** (61), 9-14 (2021).
15. А.С. Катасёв, Д.В. Катасёва, Ю.Н. Смирнов, Л.Н. Кунафина, *Вестник Технологического университета*, **27**, 10, 101-105 (2024).
16. Р.Н. Минниханов, А.С. Катасёв, Д.В. Катасёва, В. Скибин, *Вестник Технологического университета*, **27**, 11, 199-205 (2024).
17. Ja. Abdullayev, O. Ergashev, *Universum: технические науки*, **2-7** (131), 63-66 (2025).
18. S. Wang, B. Chen, *Informatics. Economics. Management*, **2**, 4, 134-144 (2023).
19. В.В. Понамарев, В.В. Китов, *Программирование*, **3**, 14-20 (2024).
20. С.А. Ляшева, М.В. Мейзер, В.М. Трегубов, М.П. Шлеймович, *Вестник Технологического университета*, **28**, 10, 108-114 (2025).
21. W. Li, K. Liu, *Sensors*, **21**, 7, 2380-2392 (2021).
22. А.С. Катасёв, Н.И. Фаттахов, *Вестник Технологического университета*, **26**, 3, 79-84 (2023).
23. А.И. Сабиров, Р.Н. Минниханов, А.С. Катасёв, Р.И. Мустафин, *Вестник Технологического университета*, **27**, 1, 87-91 (2024).
24. Ю.Н. Смирнов, А.И. Абдуллин, А.В. Каляшина, *Научно-технический вестник Поволжья*, **6**, 106-109 (2023).
25. T. Yifter, Yu. Razoumny, V. Lobanov, *Informatics and Automation*, **21**, 5, 963-982 (2022).
26. kaggle.com: сайт. – URL: <https://www.kaggle.com/datasets/delayedkarma/impressionist-classifier-data/data> (дата обращения: 23.02.2026).
27. М.В. Дагаева, Д.В. Катасёва, А.С. Катасёв, *Информация и безопасность*, **21**, 3, 366-371 (2018).
28. С.А. Игнатъева, Р.П. Богущ, *Информатика*, **20**, 1, 40-54 (2023).
29. А.Р. Обухова, М.С. Науменко, *Парадигма*, **5-2**, 26-31 (м).
30. А.Н. Степанов, Й.И. Левин, *Научные высказывания*, **12** (59), 19-23 (2024).
31. А.К. Средняков, *Наука и производство Урала*, **21**, 45-49 (2025).
32. D.M. Wonohadidjodjo, *Eduvest*, **2**, 2, 297-305 (2022).
33. S. Karthika, M. Durgadevi, T.Ya. Rani, *Annals of Data Science*, **11**, 1, 1-24 (2024).
34. А.М. Китенко, *Системы анализа и обработки данных*, **4** (84), 7-18 (2021).
35. Т.С. Евдокимова, М.П. Шлеймович, *Инженерный вестник Дона*, **2** (122), 232-241 (2025).
36. Б. Курбанов, А.С. Катасёв, Д.В. Катасёва, Б.Р. Зиннуров, *Вестник Технологического университета*, **27**, 12, 158-164 (2024).
37. Р.Р. Исламова, *Информатизация и связь*, **4**, 35-39 (2021).
38. Е.В. Скоробогатов, И.А. Степанова, В.С. Орехов, *Аналитика и контроль*, **26**, 1, 21-30 (2022).

39. Р.Н. Спири́н, Р.С. Насретди́нов, *Проблемы правовой и технической защиты информации*, 11, 52-60 (2023).

## References

1. O.A. Purnova, D.P. Nikonorov, *Economics and Management: Problems, Solutions*, **12**, 2 (155), 118-123 (2025).
2. R.I. Yusupova, R.S. Zaripova, M.G. Nuriev, *Kazan science*, 2, 201-203 (2025).
3. K.A. Matveeva, R.N. Minnikhanov, A.S. Katasev, *Herald of Technological University*, **27**, 1, 76-80 (2024).
4. YES. Nabiullin, V.V. Kononova, S.V. Novikova, *Herald of Technological University*, **24**, 6, 103-107 (2021).
5. V.S. Sunku, V. Namboodiri, R. Mukkamala, *Problems of the Regional Energetics*, 1 (65), 1-11 (2025).
6. M.A. Nagorny, *Original Research*, **15**, 4, 62-66 (2025).
7. H. Dong, *Informatics and Automation*, **23**, 6, 1869-1898 (2024).
8. N.I. Berezhnov, A.A. Sirota, *Bulletin of Voronezh State University. Series: Systems Analysis and Information Technology*, 2, 81-92 (2022).
9. V.A. Burtsev, Yu.S. Belov, *Electronic Journal: Science, Technology and Education*, 4 (39), 35-44 (2022).
10. L.B. Karshakova, A.Yu. Strashnov, S.S. Nagai, A.M. Pavlinov, *Bulletin of Science and Practice*, **11**, 8, 162-173 (2025).
11. M.V. Shibaev, *Communications. Media. Design*, **6**, 4, 5-28 (2022).
12. A.A. Nikiforov, K.V. Gudkov, *Modern information technologies*, 41 (41), 70-74 (2025).
13. Ю.Ю. Yumasheva, D.Yu. Guk, *Historical Informatics*, 3 (41), 114-155 (2022).
14. T.V. Portnova, *Components of Scientific and Technological Progress*, 7 (61), 9-14 (2021).
15. A.S. Katasev, D.V. Kataseva, Yu.N. Smirnov, L.N. Kunafina, *Herald of Technological University*, **27**, 10, 101-105 (2024).
16. R.N. Minnikhanov, A.S. Katasev, D.V. Katasyva, V. Skibin, *Herald of Technological University*, **27**, 11, 199-205 (2024).
17. Ja. Abdullayev, O. Ergashev, *Universum: technical sciences*. 2-7 (131), 63-66 (2025).
18. S. Wang, B. Chen, *Informatics. Economics. Management*, 2, 4, 134-144 (2023).
19. V.V. Ponomarev, V.V. Kitov, *Programming*, 3, 14-20 (2024).
20. S.A. Lyasheva, M.V. Meizer, V.M. Tregubov, M.P. Shleimovich, *Herald of Technological University*, **28**, 10, 108-114 (2025).
21. W. Li, K. Liu, *Sensors*, **21**, 7, 2380-2392 (2021).
22. A.S. Katasev, N.I. Fattakhov, *Herald of Technological University*, **26**, 3, 79-84 (2023).
23. A.I. Sabirov, R.N. Minnikhanov, A.S. Katasev, R.I. Mustafin, *Herald of Technological University*, **27**, 1, 87-91 (2024).
24. Yu.N. Smirnov, A.I. Abdullin, A.V. Kalyashina, *Scientific and Technical Bulletin of the Volga Region*, 6, 106-109 (2023).
25. T. Yifter, Yu. Razoumny, V. Lobanov, *Informatics and Automation*, **21**, 5, 963-982 (2022).
26. kaggle.com: website. – URL: <https://www.kaggle.com/datasets/delayedkarma/impressionist-classifier-data/data> (date of access: 23.02.2026).
27. M.V. Dagaeva, D.V. Kataseva, A.S. Katasev, *Information and Security*, **21**, 3, 366-371 (2018).
28. S.A. Ignatieva, R.P. Bogush, *Computer Science*, **20**, 1, 40-54 (2023).
29. A.R. Obukhova, M.S. Naumenko, *Paradigm*, 5-2, 26-31 (M).
30. A.N. Stepanov, J.I. Levin, *Scientific statements*, 12 (59), 19-23 (2024).
31. A.K. Srednyakov, *Science and Production of the Urals*, **21**, 45-49 (2025).
32. D.M. Wonohadidjodjo, *Eduvest*, 2, 2, 297-305 (2022).
33. S. Karthika, M. Durgadevi, T.Ya. Rani, *Annals of Data Science*, **11**, 1, 1-24 (2024).
34. A.M. Kitenko, *Data Analysis and Processing Systems*, 4 (84), 7-18 (2021).
35. T.S. Evdokimova, M.P. Shleimovich, *Engineering Bulletin of the Don*, 2 (122), 232-241 (2025).
36. B. Kurbanov, A.S. Katasev, D.V. Kataseva, B.R. Zinnurov, *Herald of Technological University*, **27**, 12, 158-164 (2024).
37. R.R. Islamova, *Informatization and communications*, 4, 35-39 (2021).
38. E.V. Skorobogatov, I.A. Stepanova, V.S. Orekhov, *Analytcs and Control*, **26**, 1, 21-30 (2022).
39. R.N. Spirin, R.S. Nasretdinov, *Problems of Legal and Technical Protection of Information*, 11, 52-60 (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; А. А. Алексеева – магистрант кафедры СИБ, КНИТУ им. А.Н. Туполева, angelina\_alekseeva\_2019@gmail.com.

© D. V. Kataseva – PhD (Technical Sci.), Associate Professor of the 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; A. A. Alekseeva – Master-Student of the ISS department, KNRTU named after A.N. Tupolev, angelina\_alekseeva\_2019@gmail.com.

Дата поступления рукописи в редакцию – 06.02.26.

Дата принятия рукописи в печать – 06.03.26.