

С. А. Ляшева, М. В. Мейзер, В. М. Трегубов,
М. П. Шлеймович

СТИЛИЗАЦИИ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ГЕНЕРАТИВНОГО ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Ключевые слова: обработка изображений, стили изображений, характеристики стиля, стилизация изображений, генерация стилизованных изображений, генеративно-состязательные сети, оценки качества стилизации изображений.

В настоящее время активно развиваются и широко внедряются технологии генеративного искусственного интеллекта. Данные технологии применяются для решения различных задач во многих сферах человеческой деятельности, в том числе для стилизации изображений в цифровом искусстве, дизайне, рекламе, развлечениях и других областях. Стилизация изображений заключается в трансформации его содержания с сохранением семантической структуры, но с изменением визуального стиля, заданного образцом или параметрами модели. Для генерации изображений применяются различные методы, из которых в статье рассмотрены нейронный перенос стиля, вариационные автокодировщики, генеративно-состязательные сети и диффузионные модели. Результаты их анализа показали, что наилучшим подходом для создания художественно стилизованных изображений является применение генеративно-состязательных сетей. Существует ряд архитектур таких сетей, среди которых были исследованы Pix2Pix, CycleGAN, StyleGAN, StarGANv и UGATIT. Их сравнительный анализ показал, что архитектура CycleGAN наилучшим образом удовлетворяет требованиям задачи стилизации изображений в стиле конкретного художника. Она не требует парных данных, демонстрирует устойчивость к различию структур изображений, и обеспечивает стабильное и воспроизводимое обучение. В совокупности эти преимущества делают CycleGAN предпочтительным выбором для построения системы художественной стилизации. Для проведения экспериментов была разработана система стилизации изображений, обученная на наборе изображений с копиями произведений Винсента Ван Гога, Клода Моне, Анри Матисса, Ивана Айвазовского и Ильи Репина. Эти авторы были выбраны по совокупности критерии: популярность, узнаваемость стиля, жанровое разнообразие и наличие достаточного числа цифровых копий работ. Для оценки качества генерации изображений были использованы метрики Kernel Inception Distance, Inception Score и Contrastive Language–Image Pretraining based cosine similarity. Результаты экспериментов показали, что генеративные модели демонстрируют потенциал в имитации общих черт художественных стилей. Однако для достижения более высокого уровня достоверности и точности необходимо проведение дальнейших исследований по их адаптации к заданным стилям.

С. А. Lyasheva, M. V. Meizer, V. M. Tregubov,
M. P. Shleymovich

IMAGE STYLIZATION BASED ON GENERATIVE ARTIFICIAL INTELLIGENCE

Keywords: image processing, image styles, style characteristics, image stylization, generation of stylized images, generative-adversarial networks, image stylization quality assessments.

Currently, generative artificial intelligence technologies are being actively developed and widely implemented. These technologies are used to solve various tasks in many areas of human activity, including image stylization in digital art, design, advertising, entertainment, and other fields. Image stylization consists in the transformation of its content while maintaining the semantic structure, but with a change in the visual style set by the sample or model parameters. Various methods are used to generate images, of which neural style transfer, variational autoencoders, generative-adversarial networks and diffusion models are considered in the article. The results of their analysis showed that the best approach for creating artistically stylized images is the use of generative-adversarial networks. There are a number of such network architectures, among which Pix2Pix, CycleGAN, StyleGAN, StarGANv and UGATIT have been investigated. Their comparative analysis showed that the CycleGAN architecture best meets the requirements of the task of stylizing images in the style of a particular painter. It does not require paired data, demonstrates resilience to different image structures, and provides stable and reproducible learning. Taken together, these advantages make CycleGAN a preferred choice for building an artistic stylization system. To conduct the experiments, an image stylization system was developed, trained on a set of images with copies of artworks by Vincent Van Gogh, Claude Monet, Henri Matisse, Ivan Aivazovsky and Ilya Repin. These authors were selected based on a set of criteria: popularity, recognition of style, genre diversity and the availability of a sufficient number of digital copies of artworks. To evaluate the quality of generated images, metrics such as Kernel Inception Distance, Inception Score, and Contrastive Language–Image Pretraining based cosine similarity were used. The experimental results showed that generative models demonstrate the potential to mimic common features of artistic styles. However, in order to achieve a higher level of reliability and accuracy, further research is needed to adapt them to the given styles.

Введение

В настоящее время технологии обработки изображений, базирующиеся на достижениях в глубоком обучении, применяются практически во всех сферах человеческой деятельности. Особенно впечатляю-

щие успехи достигнуты в системах создания изображений с заданными характеристиками, основанных на генеративном искусственном интеллекте. Одной из областей применения таких систем является создание автоматизированных инструментов для стилизации изображений.

Стилизация изображений может применяться в различных сферах, например, в цифровом искусстве, дизайне, рекламе и развлечениях. Существующие популярные решения в области стилизации изображений имеют ряд существенных недостатков. Во-первых, многие инструменты требуют текстового описания для генерации изображений, что ограничивает возможности для стилизации уже существующих изображений. Во-вторых, для доступа ко всем функциям, стилям и улучшенным возможностям, таким как более быстрая генерация, увеличенное число попыток, часто необходима платная подписка.

Поэтому исследования в области создания локальных систем художественной стилизации изображений на базе генеративного искусственного интеллекта, обеспечивающих быстрое преобразование исходных данных, являются актуальными.

Стилизация изображения заключается в трансформации его содержания с сохранением семантической структуры, но с изменением визуального стиля, заданного образцом или параметрами модели [1].

Одной из самых ярких областей применения генеративной стилизации изображений является цифровое искусство. Современные художники и дизайнеры используют технологии для создания уникальных визуальных произведений, экспериментируя с различными стилями. Генерация произведений искусства в стиле известных художников позволяет стилизовать фотографии и изображения в произведения таких мастеров, как Ван Гог, Пикассо, Моне и других, воссоздавая уникальные художественные эффекты и текстуры [2].

В образовательной сфере стилизация изображений может быть полезной для создания обучающих материалов, которые легче воспринимаются учащимися. В частности, его применение в художественном образовании расширяет возможности для экспериментов, творчества и глубокого освоения художественных стилей. Благодаря сочетанию традиционных методов с передовыми цифровыми технологиями обучение становится более гибким, доступным и эффективным [3]. Генеративный искусственный интеллект становится своего рода наставником, который помогает учащимся осваивать различные стилистические подходы, ускоряет творческий процесс и предлагает разнообразные вариации, вдохновляя на новые художественные решения.

Основной принцип обучения в художественных школах – это рисование с натуры, которое развивает наблюдательность, внимание к деталям, чувство пропорций и понимание света и тени [4]. Однако процесс переноса реальных объектов в художественные стили или эксперименты с визуальными концепциями часто сталкивается с ограничениями. Например, представить натуру в манере определенного художника или течения (например, в стиле импрессионизма или абстракционизма) может быть затруднительно, особенно для новичков, не обладающих еще достаточным мастерством или техническим опытом. Здесь на помощь приходит генеративный искусственный интеллект – если учащийся желает изобразить натуру, например, в манере импрессионизма, кубизма или в стиле определенного художника, то

можно сгенерировать варианты исполнения, которые продемонстрируют ключевые особенности и элементы выбранного стиля.

Стилизация изображений может также использоваться в дизайне, например, для создания новых моделей одежды [5]. Применение соответствующих инструментов позволяет дизайнерам ускорить процесс разработки и экспериментировать с уникальными визуальными решениями.

В киноиндустрии стилизация изображений используется для создания визуальных эффектов, которые невозможно или трудно создать традиционными методами [6]. Она применяется для создания фантастических пейзажей, костюмов, объектов и персонажей, стилизованных под определенные визуальные эстетики, что позволяет значительно ускорить процесс производства контента. Кроме того, эти технологии могут преобразовывать видеоролики в стилизованные художественные произведения, что широко используется в анимации и кинопроизводстве для достижения уникальных визуальных эффектов.

Генеративная стилизация изображений используется для создания контента в областях виртуальной и дополненной реальности [7]. Она способна преобразовывать изображения реальных объектов в стилизованные версии, которые затем используются для создания виртуальных объектов или окружающих миров. В играх и приложениях виртуальной реальности такой подход позволяет создавать уникальные и визуально разнообразные миры.

Стилизация изображений может также применяться для увеличения объема и разнообразия обучающих данных при обучении нейросетевых классификаторов [8]. В отличие от базовых трансформаций, стилизация позволяет создавать визуально отличающиеся, но семантически идентичные изображения, сохраняя ключевые объекты и формы. Это помогает моделям лучше обобщать информацию, быть устойчивыми к стилем и текстурным различиям и улучшает их точность в условиях ограниченного набора оригинальных данных.

Таким образом, визуальные эффекты, персонализированные стили и уникальные художественные решения, которые могут быть достигнуты с помощью стилизации изображений с использованием генеративного искусственного интеллекта, значительно расширяют горизонты, как для профессионалов, так и для обычных пользователей. Будущее этого направления выглядит крайне перспективным, с продолжением улучшения качества моделей и расширением их функциональности.

Анализ существующих решений

В настоящее время существует ряд сервисов, позволяющих с помощью искусственного интеллекта преобразовывать входное изображение в стили известных художников. Для сравнения можно выделить несколько ключевых критериев:

- качество стилизации;
- скорость обработки;
- гибкость настроек;
- доступность на разных платформах;
- стоимость использования.

Рассмотрим наиболее популярные из них.

Prisma – мобильное приложение, доступное для iOS и Android. Оно позволяет быстро и качественно стилизовать фотографии, применяя к ним предустановленные художественные фильтры. Скорость обработки высокая, но возможности настройки ограничены. Доступны как бесплатные фильтры, так и премиальные эффекты, за которые нужно доплачивать.

Kandinsky 3.0 – нейросеть, позволяющая генерировать изображения на основе текстовых описаний. Она предлагает широкий спектр художественных стилей и может адаптировать изображения под различные визуальные концепции. Скорость обработки высокая, позволяет изменять стили, цветовые схемы и другие параметры генерации. Доступна онлайн через веб-интерфейс, есть бесплатная версия с ограничениями, а также премиум-доступ с расширенными возможностями.

DeepArt – веб-сервис, доступный через браузер, который предлагает детализированную стилизацию изображений в стиле известных художников. Скорость обработки варьируется, так как она зависит от сложности алгоритма. Имеется бесплатная версия с ограниченным функционалом.

Deep Dream Generator – веб-сервис, который позволяет создавать изображения различных стилей. Он обеспечивает гибкую настройку параметров. Однако с его помощью не всегда результаты хорошего качества.

Методы стилизации изображений

Генерация стилизованных изображений является сложной задачей, требующим использования специализированных алгоритмов для анализа, воспроизведения и переноса стилистических особенностей изображений. Здесь применяются следующие методы.

Нейронный перенос стиля (Neural Style Transfer, NST) – это метод на основе применения сверточных нейронных сетей для извлечения и комбинирования контента и стиля двух изображений [9]. Контент представляет собой основной визуальный элемент изображения, такой как структура объектов, формы и контуры, тогда как стиль включает текстуры, цвета и паттерны, которые формируют художественное оформление изображения. Сверточные нейронные сети анализируют изображение на различных уровнях абстракции – от низкоуровневых текстур до высокоуровневых смысловых признаков. На основе признаков контента и стиля генерируется новое изображение. При этом сохраняется структура и содержание оригинала, а также воссоздаются характерные стилистические черты другого изображения.

Вариационные автокодировщики (Variational Autoencoders, VAE) – это один из подходов к генеративному моделированию, позволяющий создавать новые изображения, обучаясь на имеющихся данных [10]. VAE состоит из двух основных компонентов – энкодера и декодера. Энкодер преобразует входные данные (например, изображения) в параметры скрытого пространства, а декодер восстанавливает данные из этого пространства. В отличие от обычных автозадекодеров, VAE моделирует скрытое пространство

как вероятностное распределение, что позволяет генерировать новые данные путем выборки из этого распределения.

Генеративно-состязательные сети (Generative Adversarial Networks, GAN) – это класс моделей машинного обучения GAN, которые состоят из двух нейронных сетей – генератора и дискриминатора [11]. Генератор принимает на вход случайный шум (обычно вектор из нормального распределения) и пытается сгенерировать данные, которые похожи на реальные (например, изображения). Его цель заключается в том, чтобы обмануть дискриминатор, заставив его поверить, что сгенерированные данные являются настоящими. Дискриминатор – это классификатор, который пытается отличить реальные данные (например, изображения из обучающей выборки) от сгенерированных генератором. Его цель – правильно определить, является ли входное изображение настоящим или поддельным.

Диффузионные модели (Diffusion Models, DM) – методы генерации изображений, которые основываются на методе постепенного добавления шума к данным и их восстановлении [12]. На начальном этапе изображения постепенно «зашумляются» путем добавления синтетического шума. На следующем этапе диффузионная модель восстанавливает изображение, начиная с сильно зашумленного состояния. Основной задачей является минимизация разности между восстановленным изображением и исходным изображением на каждом этапе.

Результаты сравнения рассмотренных методов показали, что наилучшим из них для создания стилизованных изображений является GAN. Он обеспечивает высокое качество, реалистичность и высокую скорость генерации.

Существует ряд архитектур GAN, адаптированных под задачи стилизации, отличающихся как по методам обучения, так и по механизмам внедрения стилевых признаков [13].

Одним из первых подходов к стилизации с использованием GAN стала архитектура Pix2Pix, основанная на условной генеративно-состязательной сети (Conditional GAN). Модель обучается на парных данных (изображение до и после стилизации). Однако, в случае художественной стилизации, когда отсутствует возможность сформировать такие пары (например, фотография и эквивалентная ей картина в стиле Ван Гога), использование данной модели становится затруднительным.

Для решения задачи беспарного преобразования изображений была предложена архитектура CycleGAN с двумя генераторами и двумя дискриминаторами. Данный подход показал высокую эффективность в задаче переноса художественного стиля, позволяя работать с датасетами, содержащими лишь непарные примеры изображений в исходном и целевом стилях.

Также был предложен подход StyleGAN, в котором вводится стиль в латентное пространство через последовательность нелинейных преобразований и используется аддитивная нормализация, когда латентный вектор сначала проецируется в скрытое стилевое пространство, а затем управляет генератором

на различных уровнях. Структура изображения определяется геометрией слоёв, а стиль внедряется через нормализацию, обеспечивая отделение формы и текстурных характеристик. Несмотря на высокое качество получаемых изображений, StyleGAN требует дополнительной инверсии латентного кода для стилизации конкретного входного изображения, что ограничивает его прямое применение в рассматриваемой задаче.

Более универсальной в плане трансфера между множеством доменов является архитектура StarGAN v2, которая вводит механизм стилевого кодирования, позволяя задавать стиль как вектором, так и эталонным изображением. Генератор получает на вход изображение и стилевой вектор, что делает возможным мультимодальный трансфер. Однако сложность настройки и необходимость в хорошо сбалансированном датасете из множества доменов делают данную архитектуру менее применимой в условиях ограниченных данных.

В модели U-GAT-IT реализован механизм внимания, повышающий чувствительность генератора к ключевым локальным признакам, а также используется модифицированная адаптивная нормализация. Эти модификации позволяют добиться более выразительной локальной стилизации, особенно в задачах трансформации лиц. Однако обобщение модели на более широкие художественные стили требует дополнительной адаптации.

Сравнительный анализ генеративно-состязательных моделей показал, что архитектура CycleGAN наилучшим образом удовлетворяет требованиям задачи стилизации изображений в стиле конкретного художника. Она не требует парных данных, демонстрирует устойчивость к различию структур изображений, и обеспечивает стабильное и воспроизводимое обучение. В совокупности эти преимущества делают CycleGAN предпочтительным выбором для построения системы художественной стилизации.

Система стилизации изображений

Для проведения экспериментов была разработана система стилизации изображений, обученная на датасете, содержащем изображения с копиями картин Винсента Ван Гога, Клода Моне, Анри Матисса, Ивана Айвазовского и Ильи Репина. Эти авторы были выбраны по совокупности критериев: популярность, узнаваемость стиля, жанровое разнообразие и наличие достаточного числа цифровых копий работ. Для анализа художественных стилей были использованы средние значения интенсивностей отдельных цветовых компонентов, контраста, резкости, насыщенности и плотности границ. На рис. 1 слева направо и сверху вниз показаны входное тестовое изображение и изображения, полученные в результате генерации в стилях Моне, Ван Гога, Матисса, Айвазовского и Репина.

В таблице 1 приведены значения времени генерации одного изображения с использованием CPU, а в таблице 2 – использованием GPU. Эксперименты проводились с применением компьютера, оснащённого процессором Intel Core i5-11300H, 16 Гб оперативной памяти, дискретной видеокартой NVIDIA

GeForce RTX 3050 с 4 Гб видеопамяти и твердотельным накопителем объёмом 512 Гб. В качестве операционной системы использовалась Windows 10 Pro.



Рис. 1 – Стилизация изображений

Fig. 1 – Image stylization

Проведенный анализ показал, что все тестируемые модели обладают сопоставимой производительностью при стилизации изображений. Разница в скорости обработки между моделями незначительна, но стабильно прослеживается как в средних, так и в экстремальных значениях. Все генеративные модели демонстрируют приемлемую эффективность для практического применения.

Для оценки качества сгенерированных изображений были использованы метрики KID (Kernel Inception Distance), IS (Inception Score) и CLIP (Contrastive Language–Image Pretraining) [14, 15, 16].

Таблица 1 – Время генерации изображений с использованием CPU

Художник	Среднее время (сек)	Мин. время (сек)	Макс. время (сек)
Айвазовский	0.93	0.43	2.21
Ван Гог	0.99	0.40	2.15
Матисс	0.94	0.47	2.19
Моне	1.03	0.50	2.42
Репин	0.95	0.43	2.14

Таблица 2 – Время генерации изображений с использованием GPU

Художник	Среднее время (сек)	Мин. время (сек)	Макс. время (сек)
Айвазовский	0.083	0.069	0.102
Ван Гог	0.084	0.066	0.118
Матисс	0.079	0.065	0.102
Моне	0.083	0.069	0.094
Репин	0.082	0.066	0.100

KID – метрика, используемая для оценки сходства между реальными и сгенерированными изображениями. Она основана на расчете расстояния между распределениями признаков реальных и сгенерированных изображений, извлеченных из слоя нейросети Inception. Чем меньше значение KID, тем лучше качество сгенерированных изображений ($KID \approx 0$ означает отличное качество генерации), то есть они ближе по стилю и содержанию к настоящим изображениям. При использовании в исследовании принято рассчитывать среднее и стандартное отклонение KID по нескольким подвыборкам, чтобы оценить надёжность генерации.

IS – метрика, предназначенная для оценки качества и разнообразия сгенерированных изображений. Она использует предобученную нейросеть (обычно Inception-v3). Она оценивает два аспекта: семантическую однозначность (насколько вероятно, что изображение принадлежит одному классу) и разнообразие (насколько изображения разнообразны по категориям). Высокий IS свидетельствует о четких и разнообразных изображениях, тогда как низкий – указывает на размытость, неразборчивость или однотипность генераций. Поскольку метрика заточена под классификацию объектов, она особенно чувствительна к тому, насколько изображения распознаются предобученной моделью. В случае художественных стилей, где содержимое не всегда поддается однозначной классификации, IS следует дополнять другими метриками, а также визуальной экспертизой.

CLIP – метрика, которая используется для оценки семантического сходства между изображениями. Она показывает, насколько два изображения похожи с точки зрения высокоуровневого содержания, а не пиксельной схожести. Косинусное сходство варьируется от -1 до 1, где 1 означает полное совпадение, 0 – отсутствие сходства и -1 – противоположное содержание.

Эти метрики позволяют оценить визуальное сходство с реальными изображениями, разнообразие и реалистичность генерации, а также семантическое соответствие стилю оригинального художника.

В таблице 3 приведены значения метрик, рассчитанные по 100 сгенерированным тестовым изображениям. Значения KID mean и KID std были получены путем вычисления среднего значения из показателей, полученных за 10 тестов.

Таблица 3 – Значения метрик

Table 3 – Metric values

Художник	KID mean	KID std	IS	CLIP
Айвазовский	0,057	0,006	4.351	0.3967
Ван Гог	0.038	0.004	4.487	0.378
Матисс	0.043	0.005	4.494	0.417
Моне	0,034	0,004	4.449	0.416
Репин	0.081	0.008	4.640	0.323

Наилучшее качество по метрике IS было получено для изображений в стиле Репина. Однако их сходство оказалось невысоким по метрикам CLIP и KID. Это связано со сложностью стиля для точности генерации подобных изображений. Изображения в стиле Моне и Матисса, наоборот, показывают лучшие результаты по метрикам KID и CLIP. Однако значения метрики IS показывают, что они обладают меньшим разнообразием. Изображения в стиле Van Gogh имеют низкие показатели IS и CLIP, что может свидетельствовать о том, что его стиль труднее генерировать с высоким качеством и точностью. Изображения в стиле Айвазовского находятся ближе к середине: его изображения имеют средние значения KID и CLIP, а также самый низкий IS, что может указывать на недостаточное разнообразие в генерации при умеренной стилистической точности.

Так же для оценки качества генерации был разработан классификатор изображений, принадлежащих различным художникам. В качестве основы для классификации использовалась сверточная нейронная сеть EfficientNet-B2, предварительно обученная на большом датасете изображений. Модель была адаптирована под задачу классификации изображений художников путем модификации последних слоев сети, что позволило ей учитывать специфические особенности данного набора данных. Листинг классификатора приведен в приложении 5.

Для обучения классификатора использовался собранный ранее датасет работ художников, дополненный работами следующих художников: Альберт Дюрер, Алесандро Ботичелли, Эгон Шиле, Фра Ангелико, Гюстав Дор, Харрисон Фишер, Иван Шишкин, Ян Брейгель (Старший), Жан-Леон Жером, Жан Энгр, Джошуа Рейнольдс, Поль Сезанн, Поль Гоген, Рембрандт, Тициан, Василий Кандинский и Зинаида Серебрякова.

Модель показала высокую точность на обучающих данных, что свидетельствует о хорошем запоминании стилевых особенностей, но также может указывать на переобучение. Среди интересующих художников лучше всего классифицируются работы Айвазовского (0.992), благодаря его уникальному стилю. Произведения Van Gogh (0.936) и Матисса (0.935) также распознаются хорошо за счёт выраженной манеры письма. Точность по работам Моне (0.922) немного ниже – вероятно, из-за схожести его работ с другими импрессионистами. Худшие результаты оказались для произведений Репина (0.884), что, скорее всего, связано с реалистической манерой и стилистическим пересечением с другими художниками.

Далее модель классификатора была протестирована на сгенерированных изображениях, в стилях художников.

На сгенерированных изображениях в стиле Айвазовского классификатор показал точность 88%, что ниже 99.23% на обучающих данных. Часть изображений ошибочно отнесена к авторам с реалистичной манерой (Рембрандт, Шишкин, Репин).

На сгенерированных изображениях в стиле Van Gogh классификатор правильно распознал 59% изоб-

ражений, что значительно ниже точности на обучающих данных. Основные ошибки приходят на Моне и Матисса, что может указывать на путаницу между постимпрессионистами с похожими яркими и экспрессивными стилями.

На сгенерированных изображениях в стиле Матисса классификатор правильно определил 72% изображений, что ниже точности на обучающих данных. Ошибки в сторону Моне, Гогена и Ван Гога указывают на путаницу с близкими стилями.

На сгенерированных изображениях в стиле Моне классификатор достиг точности 81%, что всё ещё ниже 92.19% на обучающих данных. Основные ошибки приходятся на стилистически близких авторов – Матисса, Ван Гога и Гогена.

На сгенерированных изображениях в стиле Репина классификатор показал самый худший результат – определил 47% изображений. Ошибки в сторону Шишкина и Айвазовского указывают на схожесть их работ с реалистической манерой Репина. Также были предсказания в пользу других художников с элементами реализма (Рембрандт, Фишер).

Таким образом, генеративные модели демонстрируют потенциал в имитации общих черт художественных стилей. Для достижения более высокого уровня достоверности и точности при генерации изображений требуется их дальнейшая адаптация.

Заключение

Результаты исследования показали возможность создания системы для цифрового творчества. Подобные системы могут быть полезны в качестве инструмента для демонстрации художественных стилей, для создания концептов и вариаций на основе известных художественных движений, для формирования интерактивных экспозиций и т.д. На их основе может быть обеспечена генерация необходимого количества данных для обучения нейросетевых классификаторов.

Перспективными направлениями дальнейшей работы являются создание облачного интерфейса и реализация гибкого управления степенью стилизации.

Литература

1. M. Huang, *Journal of Computing and Electronic Information Management*, **15**, 3, 66–70 (2024).
2. A.A. Никитина, *Культура и технологии*, **8**, 4, 176-185 (2023). DOI: 10.17586/2587-800X-2023-8-4-176-185.
3. Т.В. Шорина, М.В. Мейзер, В сб. *Международный форум Kazan Digital Week*, Научный центр безопасности жизнедеятельности, Казань, 2024. С. 1304–1308.
4. Д.В. Кислица, В сб. *Гуманитарные и общественные науки: проблемы, теория, практика*, АПНИ, Белгород, 2021. С. 43–46.
5. М.Д. Демидова, Е.С. Рыкова, *Materials and Technologies*, **2**, 14, 61–67 (2024). DOI: 10.24412/2617-149X-2024-2-61-67.
6. А.М. Поляков, Т.С. Романишина, В.А. Бондаренко, *Практический маркетинг*, **2**, 332, 4–10 (2025). DOI: 10.24412/2071-3762-2025-2332-4-10.
7. J. Fischer, D. Bartz, W. Straber, In Proc. *IEEE Proceedings. VR 2005. Virtual Reality*, IEEE, 2005. P. 195–202.

8. Q. Yang, C. Ji, H. Luo, P. Li, Z. Ding, In Proc. *6th International Conference on Computer Vision, Image and Deep Learning (CVIDL)*, 2025. P. 693–696.
9. L.A. Gatys, A.S. Ecker, M. Bethge, In Proc. *IEEE Conf. on Computer Vision and Pattern Recognition*, IEEE, 2016. P. 2414–2423.
10. Д. Фостер, *Генеративное глубокое обучение: творческий потенциал нейронных сетей*. Питер, Санкт-Петербург, 2020. 336 с.
11. I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, *Communications of the ACM*, **63**, 11, 139–144 (2020). DOI: 10.1145/3422622.
12. H. Chen, Q. Xiang, J. Hu, M. Ye, C. Yu, H. Cheng, L. Zhang , *Artificial Intelligence Review*, **58**, Article No 99 (2025). DOI: 10.1007/s10462-025-11110-3.
13. M. Kang, J. Shin, J. Park, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **45**, 12, 15725–15742 (2023). DOI: 10.1109/TPAMI.2023.3306436.
14. M. Binkowski, D.J. Sutherland, M. Arbel, A. Gretton. *Demystifying MMD GANs*, arXiv:1801.01401 (2018).
15. Y. Choi, Y. Uh, J. Yoo, J.-W. Ha, In Proc. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2020. P. 8185–8194.
16. A. Radford, J.W. Kim, C. Hallacy, A. Ramesh, G. Goh, S. Agarwal, G. Sastry, A. Askell, P. Mishkin, J. Clark, G. Krueger, I. Sutskever, In Proc. *International conference on machine learning*, PMLR, 2021. P. 8748–8763.

References

1. M. Huang, *Journal of Computing and Electronic Information Management*, **15**, 3, 66–70 (2024).
2. A.A. Nikitina, *Kultura i texnologii*, **8**, 4, 176-185 (2023). DOI: 10.17586/2587-800X-2023-8-4-176-185.
3. Т.В. Шорина, М.В. Мейзер, В сб. *Международный форум Kazan Digital Week*, Научный центр безопасности жизнедеятельности, Казань, 2024. С. 1304–1308.
4. D.V. Kislicza, В сб. *Gumanitarnye i obshhestvennye nauki: problemy, teoriya, praktika*, APNI, Belgorod, 2021. P. 43–46.
5. M.D. Demidova, E.S. Rykova, *Materials and Technologies*, **2**, 14, 61–67 (2024). DOI: 10.24412/2617-149X-2024-2-61-67.
6. A.M. Polyakov, T.S. Romanishina, V.A. Bondarenko, *Prakticheskij marketing*, **2**, 332, 4–10 (2025). DOI: 10.24412/2071-3762-2025-2332-4-10.
7. J. Fischer, D. Bartz, W. Straber, In Proc. *IEEE Proceedings. VR 2005. Virtual Reality*, IEEE, 2005. P. 195–202.
8. Q. Yang, C. Ji, H. Luo, P. Li, Z. Ding, In Proc. *6th International Conference on Computer Vision, Image and Deep Learning (CVIDL)*, 2025. P. 693–696.
9. L.A. Gatys, A.S. Ecker, M. Bethge, In Proc. *IEEE Conf. on Computer Vision and Pattern Recognition*, IEEE, 2016. P. 2414–2423.
10. D. Foster, *Generativnoe glubokoe obuchenie: tvorcheskij potencial nejronnyx setej*. Piter, Sankt-Peterburg, 2020. 336 p.
11. I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, *Communications of the ACM*, **63**, 11, 139–144 (2020). DOI: 10.1145/3422622.
12. H. Chen, Q. Xiang, J. Hu, M. Ye, C. Yu, H. Cheng, L. Zhang , *Artificial Intelligence Review*, **58**, Article No 99 (2025). DOI: 10.1007/s10462-025-11110-3.
13. M. Kang, J. Shin, J. Park, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **45**, 12, 15725–15742 (2023). DOI: 10.1109/TPAMI.2023.3306436.
14. M. Binkowski, D.J. Sutherland, M. Arbel, A. Gretton. *Demystifying MMD GANs*, arXiv:1801.01401 (2018).

15. Y. Choi, Y. Uh, J. Yoo, J-W. Ha, In Proc. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020. P. 8185–8194.
16. A. Radford, J.W. Kim, C. Hallacy, A. Ramesh, G. Goh, S. Agarwal, G. Sastry, A. Askell, P. Mishkin, J. Clark, G. Krueger, I. Sutskever, In Proc. International conference on machine learning, PMLR, 2021. P. 8748–8763.

© С. А. Лишева – канд. техн. наук, доцент кафедры Прикладной математики и информатики, Казанский национальный исследовательский технический университет им. А.Н. Туполева (КНИТУ ими. А.Н. Туполева), Казань, Россия, salyasheva@kai.ru; М. В. Мейзер – магистрант кафедры Автоматизированных систем обработки информации и управления (АСОИУ), КНИТУ им. А.Н. Туполева, mmejzer@mail.ru; В. М. Трегубов – канд. техн. наук, директор Института компьютерных технологий и защиты информации, КНИТУ им. А.Н. Туполева, vmtregubov@kai.ru; М. П. Шлеймович – канд. техн. наук, заведующий кафедрой АСОИУ, КНИТУ им. А.Н. Туполева, mpshleymovich@kai.ru.

© S. A. Lyasheva – PhD (Technical Sci.), Associate Professor of the Department of Applied Mathematics and Informatics, Kazan National Research Technical University named after A. N. Tupolev (KNRTU named after A. N. Tupolev), Kazan, Russia, salyasheva@kai.ru; M. V. Meizer – Master-student of the Department of Automated Systems for Information Processing and Control (ASIPC), KNRTU named after A. N. Tupolev, mmejzer@mail.ru; V. M. Tregubov – PhD (Technical Sci.), Director of the Institute for Computer Technologies and Information Protection, KNRTU named after A. N. Tupolev, vmtregubov@kai.ru; M. P. Shleymovich – PhD (Technical Sci.), Head of the ASIPC department, KNRTU named after A. N. Tupolev, mpshleymovich@kai.ru.

Дата поступления рукописи в редакцию – 23.10.25.

Дата принятия рукописи в печать – 30.10.25.