

ИНТЕЛЛЕКТУАЛЬНЫЕ ТЕХНОЛОГИИ ОБРАБОТКИ ГРАФИЧЕСКОЙ ИНФОРМАЦИИ В ОБЛАСТИ БЕЗОПАСНОСТИ В ЧРЕЗВЫЧАЙНЫХ СИТУАЦИЯХ

✉Лабинский Александр Юрьевич.

Санкт-Петербургский университет ГПС МЧС России, Санкт-Петербург, Россия

✉Labinsciy@yandex.ru

Аннотация. Актуальность исследования обусловлена стремительным ростом объёмов графической информации, поступающей от беспилотных систем, видеонаблюдения, спутниковой разведки и других источников, используемых при мониторинге и ликвидации последствий чрезвычайных ситуаций.

В работе представлен комплексный обзор современных методов обработки графической информации, основанных на технологиях искусственного интеллекта, включая сверточные нейронные сети, генеративно-сопоставительные сети и вариационные автокодировщики. Рассмотрены основные направления применения интеллектуальных моделей для анализа и генерации изображений, их роль в задачах классификации, сегментации, обнаружения объектов, восстановления изображений, моделирования возможных сценариев развития чрезвычайных ситуаций и формирования синтетических обучающих данных.

Результаты исследования демонстрируют, что применение глубоких нейросетевых моделей позволяет существенно повысить точность, скорость и надёжность обработки графических данных, что расширяет функциональные возможности систем мониторинга, предупреждения и реагирования на чрезвычайные ситуации.

Ключевые слова: искусственный интеллект, модель искусственного интеллекта, глубокое обучение, распознавание изображений, генерация изображений, нейронная сеть, вариационный автокодировщик

Для цитирования: Лабинский А.Ю. Интеллектуальные технологии обработки графической информации в области безопасности в чрезвычайных ситуациях // Природные и техногенные риски (физико-математические и прикладные аспекты). 2025. № 4 (56). С. 51–62. DOI: 10.61260/2304-0130-2025-2-51-62.

Analytical article

INTELLIGENT TECHNOLOGIES FOR GRAPHIC INFORMATION PROCESSING IN THE FIELD OF SAFETY IN EMERGENCY SITUATIONS

✉Labinsky Alexander Yu.

Saint-Petersburg university of State fire service of EMERCOM of Russia, Saint-Petersburg, Russia

✉Labinsciy@yandex.ru

Abstract. The relevance of this study is driven by the rapid growth of graphic data coming from unmanned aerial vehicles, video surveillance, satellite reconnaissance, and other sources used in emergency monitoring and response.

This paper presents a comprehensive overview of modern methods for processing graphic data based on artificial intelligence technologies, including convolutional neural networks, generative adversarial networks, and variational autoencoders.

It examines the main applications of intelligent models for image analysis and generation, as well as their role in classification, segmentation, object detection, image restoration, modeling possible emergency scenarios, and generating synthetic training data.

The study's results demonstrate that the use of deep neural network models can significantly improve the accuracy, speed, and reliability of graphic data processing, thereby expanding the functionality of emergency monitoring, warning, and response systems.

Keywords: artificial intelligence, model of artificial intelligence, deep learning, image recognition, image generation, neural network, variable autocoder

For citation: Labinsky A.Yu. Intelligent technologies for graphic information processing in the field of safety in emergency situations // Prirodnye i tekhnogennye riski (fiziko-matematicheskie i prikladnye aspekty) = Natural and man-made risks (physico-mathematical and applied aspects). 2025. № 4 (56). P. 51–62. DOI: 10.61260/2307-7476-2025-4-51-62.

Введение

Современное развитие информационных и коммуникационных технологий приводит к стремительному росту объёмов графической информации, поступающей из различных источников: беспилотных летательных аппаратов, систем видеонаблюдения, спутниковых комплексов, мобильных устройств оперативных служб, средств мониторинга технических объектов и окружающей среды. В условиях чрезвычайных ситуаций (ЧС), связанных как с природными катастрофами, так и с техногенными авариями, именно графическая информация становится критически важной для своевременного принятия решений, оценки обстановки и координации действий служб реагирования. Высокая динамика событий, неопределённость факторов, изменчивость условий и ограниченность времени требуют применения интеллектуальных методов анализа визуальных данных, способных работать в реальном времени, повышать точность распознавания объектов и автоматизировать процессы ситуационной аналитики.

Актуальность исследования определяется необходимостью повышения эффективности методов обеспечения безопасности при ЧС, что предполагает внедрение современных технологий искусственного интеллекта (ИИ) в процессы обработки графической информации. Интеллектуальные модели позволяют автоматизировать такие задачи, как классификация изображений, сегментация объектов, обнаружение аномалий, реконструкция визуальных данных, а также генерация изображений для моделирования различных сценариев развития обстановки. Эти возможности открывают новые перспективы для систем предупреждения ЧС, мониторинга территорий, управления эвакуацией, оценки ущерба и планирования спасательных операций.

Возникновение и бурное развитие технологий глубокого обучения и компьютерного зрения (GIP – Graphical Information Processing) предлагает фундаментальный сдвиг в парадигме управления рисками и реагирования на ЧС. GIP позволяет обрабатывать гигантские и непрерывно поступающие потоки графических данных. Интеллектуальные системы могут трансформировать хаотичный поток сырой информации в структурированные, оперативно применимые данные для принятия решений. Эти технологии, обеспечивая высокую скорость и объективность оценки, являются ключевым элементом для повышения устойчивости городских инфраструктур и обеспечения безопасности населения.

Вопросам разработки систем обработки графической информации с использованием технологий ИИ посвящено множество работ [1–5].

Цель исследования заключается в проведении комплексного обзора возможностей интеллектуальных технологий обработки графической информации, применяемых для обеспечения безопасности в ЧС.

Интеллектуальные технологии обработки графической информации

Можно выделить два основных направления применения интеллектуальных технологий обработки графической информации – анализ и генерация изображений.

Анализ изображений является одной из наиболее критически важных задач в деятельности МЧС России и других служб, задействованных в реагировании на ЧС. Под анализом изображений понимается комплекс методов, позволяющих автоматически извлекать информацию из визуальных данных: фотографий, видеопотоков, тепловизионных кадров, спутниковых снимков, изображений, полученных от дронов или камер наблюдения. Эти методы используются на всех этапах управления ЧС – от раннего предупреждения до ликвидации последствий. Одной из наиболее значимых сфер применения анализа изображений является мониторинг природных и техногенных угроз. Системы компьютерного зрения позволяют автоматически обнаруживать: очаги возгорания на лесных и промышленных территориях; задымление, повышение температурного фона, тепловые аномалии; оползневые сдвиги, трещины, деформации склонов; признаки аварий на промышленных объектах (утечки, вспышки, разрушения).

Современные алгоритмы позволяют распознавать объекты, выделять зоны разрушений, находить пострадавших, оценивать состояние инфраструктуры и определять границы опасных участков. Например, системы мониторинга лесных пожаров способны автоматически находить очаги возгораний по снимкам в реальном времени, а алгоритмы сегментации позволяют точно определять границы затопленных зон или разрушенных зданий. Всё это помогает спасателям быстрее понимать масштабы ситуации и правильно распределять ресурсы.

Важным направлением анализа является работа с видеопотоком. Она позволяет отслеживать динамику развития событий: распространение огня или дыма, перемещение людей, изменение дорожной обстановки, состояние мостов и других объектов. Особенно это актуально при управлении дронами, которые постоянно передают изображения с воздуха. Компьютерное зрение в таких условиях выступает в качестве помощника оператора, снижая вероятность ошибки и обеспечивая мгновенную реакцию на изменения.

Анализ изображений также используется на этапе ликвидации последствий. После ЧС необходимо оценить ущерб, документировать разрушения, составлять карты районов бедствия. Алгоритмы классификации и детекции облегчают эти процессы, позволяя автоматически выделять повреждённые участки, определять уровень разрушений или анализировать состояние объектов.

В условиях ЧС нередко наблюдается нехватка данных для обучения, например, для редких типов ЧС или уникальных условий. Интеллектуальные технологии позволяют компенсировать дефицит данных путём генерации дополнительных изображений. Генерация изображений существенно повышает качество машинного обучения при ограниченных наборах реальных данных. Генеративные модели, особенно GAN и VAE, позволяют: восстанавливать фрагменты изображений, потерянные из-за дыма, пыли, плохой камеры; повышать чёткость изображений, снятых с большого расстояния; удалять шумы, атмосферные искажения; увеличивать разрешение снимков; восстанавливать кадры видеопотока. Эти возможности чрезвычайно важны при работе с данными, полученными в экстремальных условиях.

Модели вроде StackGAN, AttnGAN или ChatPainter умеют создавать изображения по тексту. Это открывает возможности визуализировать обстановку на основе докладов спасателей, генерировать изображения для отчётов и карт, визуально воспроизводить описания очевидцев.

Одно из ключевых применений генерации – моделирование возможных ситуаций. Например, можно воспроизводить, как будет распространяться пожар при разных условиях, как разрушится здание при землетрясении или как изменится уровень воды при подъёме реки. Изображения помогают в планировании, обучении персонала и анализе рисков.

Специалисты могут заранее видеть возможные варианты развития событий, даже если реальные данные отсутствуют.

Таким образом, анализ изображений обеспечивает оперативность и точность оценки ситуаций на месте событий, тогда как генерация изображений предоставляет гибкие инструменты для моделирования, восстановления и обучения. Обе технологии в совокупности значительно повышают устойчивость систем безопасности и позволяют службам ЧС действовать быстрее, точнее и безопаснее.

Модели ИИ, используемые для распознавания изображений

Для распознавания изображений обычно используются нейронные сети. Так как вектор входных данных, связанный с размером изображения, может иметь очень большой размер, использование классических многослойных нейронных сетей прямого распространения затруднено. В этом случае используются сверточные нейронные сети (CNN – Convolutional Neural Network), которые содержат чередующиеся сверточные, субдискретизирующие и полносвязные слои [6]. При этом, по сравнению с классическими нейронными сетями, снижается сложность обучения и повышается устойчивость к различным искажениям изображения.

CNN основаны на идее локального восприятия, согласно которой каждому нейрону соответствует ограниченная область входного изображения – так называемое «поле восприятия». Сеть постепенно извлекает особенности различной степени абстракции: от простых линий и контуров на ранних слоях до сложных структур – зданий, людей, транспортных средств – на более глубоких уровнях.

Наличие в сверточной нейронной сети слоев субдискретизации и полносвязных слоев обеспечивает сжатие входного изображения [7]. Общая структура сверточной нейронной сети представлена на рис. 1.




Рис. 1. Структура сверточной нейронной сети

CNN демонстрируют высокую эффективность при решении широкого спектра задач, связанных с обеспечением безопасности в ЧС:

- классификация объектов: определение типа пожарных очагов, классификация разрушенных объектов, распознавание транспортных средств, пострадавших или элементов инфраструктуры;
- обнаружение объектов: выделение людей в зоне поражения, определение границ разрушенных зданий, локализация источников возгорания;
- сегментация изображений: разделение изображения на функциональные зоны – пожарные очаги, уровни затопления, зоны повреждений;
- анализ тепловизионных данных: выявление температурных аномалий, локализация источников теплового излучения при поисково-спасательных операциях;

– мониторинг с беспилотных аппаратов: обработка потокового видеосигнала для выявления опасных объектов в реальном времени [8].

Особое значение CNN приобретают в задачах автоматического анализа изображений сложных сцен, включающих большое количество объектов, нестандартные ракурсы и различные условия освещённости. В целом CNN являются базовым инструментом анализа изображений и служат фундаментом для разработки комплексных систем поддержки принятия решений при ЧС.

Модели ИИ, используемые для генерации изображений

Автоматическое создание реалистичных высококачественных изображений из текстовых описаний имеет множество практических применений.

Для генерации изображений в настоящее время используются генеративные модели, использующие метод глубокого обучения. Среди них можно выделить вариационные автокодировщики (Variational AutoEncoder, VAE) и генеративно-сопоставительные сети (Generative Adversarial Networks, GAN).

GAN представляют собой класс моделей глубокого обучения, которые используют принцип состязательного обучения между двумя нейронными сетями – генератором и дискриминатором. Генератор стремится создать реалистичные изображения, максимально схожие с настоящими, в то время как дискриминатор пытается отличить синтетические данные от реальных. Противостояние позволяет модели постепенно улучшать качество генерируемых данных [9], что делает GAN одним из наиболее перспективных инструментов обработки графической информации, особенно в условиях ЧС.

GAN позволяют восстанавливать повреждённые изображения, генерировать недостающие фрагменты, реконструировать сцены, создавать синтетические данные для обучения других моделей, улучшать качество изображений, полученных в сложных условиях (дым, туман, низкое освещение). В контексте задач безопасности при ЧС данная технология обладает огромным потенциалом, позволяя формировать дополнительные обучающие наборы данных, моделировать опасные сценарии и поддерживать автоматизированные системы анализа.

Ниже представлены ключевые разновидности GAN, наиболее значимые для обработки графических данных.

Глубокая сверточная генеративная состязательная сеть (Deep Convolutional GAN, DCGAN).

DCGAN является одной из первых успешных архитектур GAN, основанных на свёрточных нейронных сетях. Её ключевая особенность – отказ от полносвязных слоёв в пользу исключительно свёрточных и транспонированных свёрточных слоёв.

Использование свёрточных слоёв позволяет улучшить качество генерируемых изображений. Устойчивая структура делает обучение более стабильным по сравнению с ранними моделями. Простота архитектуры способствует широкому применению, как исследователями, так и инженерами.

Возможности DCGAN для ЧС заключаются в генерации синтетических данных для обучения детекторов объектов в условиях нехватки реальных примеров [10], восстановлении изображений, полученных при плохой видимости, создании реалистичных моделей разрушений и аномалий для обучения операторов и алгоритмов прогнозирования.

Модель StackGAN.

Составные генеративные состязательные сети (Stacked Generative Adversarial Networks, StackGAN) состоят из двух последовательных генеративных сетей, каждая из которых отвечает за определённый этап генерации изображения. Первая сеть создаёт изображение низкого разрешения на основе текстового описания. Вторая сеть уточняет изображение, улучшая детали и повышая разрешение.

На первом этапе StackGAN рисует примитивную форму и цвета объекта на основе данного текстового описания, получая изображения Stage-I с низким разрешением.

На втором этапе StackGAN принимает результаты Stage-I и текстовые описания в качестве входных данных и генерирует изображения высокого разрешения с фотореалистичными деталями.

Возможности StackGAN заключаются в превращении текстовых описаний в высококачественные изображения, при этом характеризуются высокой детализацией объектов.

Применение при ЧС: для генерации изображений на основе оперативных текстовых докладов [11]; создание визуальных моделей развития ЧС, описанных экспертами; визуализация возможных сценариев для обучения персонала.

Модель FusedGAN.

Для улучшения генерации изображений по описанию и получения контролируемой выборки данная модель разделяет процесс генерации на два этапа. На первом этапе раздельная генерация фона и переднего плана позволяет получить контролируемую выборку (фиксируя фон и меняя основную сцену, и наоборот). На втором этапе с помощью контролируемой выборки различных изображений генерируется итоговая выборка высокого разрешения.

Особенности FusedGAN состоят в использовании двух источников информации – скрытый вектор и условные данные. Это позволяет генерировать более вариативные и гибкие изображения, восстанавливать недостающие детали на реальных изображениях [12].

Модель ChatPainter.

В данной модели, в отличие от рассмотренных выше, в качестве дополнительных данных используются диалоги, которые дополнительно описывают сцены. Это приводит к значительному улучшению качества генерируемых изображений.

Архитектура модели ChatPainter опирается на модель StackGAN и генерирует изображение в два этапа: на первом этапе генерируется грубое изображение, а на втором генерируется уже улучшенное изображение.

Практическое значение состоит в возможности визуализации обстановки по фрагментарной информации от операторов и очевидцев, создания детализированных изображений зон бедствия по описанию спасателей, возможность пошагового уточнения деталей.

Модель StackGAN++.

Хотя генерирующие состязательные сети (GAN) показали замечательный успех в различных задачах, они все еще сталкиваются с проблемами при создании изображений высокого качества.

StackGAN++ состоит из нескольких генераторов и нескольких дискриминаторов, организованных в древовидную структуру. Входные данные сети можно рассматривать как корень дерева, а изображения разного масштаба генерируются из разных ветвей дерева. Конечная цель генератора на самой глубокой ветви – создание фотореалистичных изображений с высоким разрешением. Генераторы в промежуточных ветвях имеют прогрессивную цель создания изображений от малых до больших для достижения конечной цели. Вся сеть совместно обучается аппроксимировать различные, но сильно взаимосвязанные распределения изображений в разных ветвях. Кроме того, используется регуляризация согласованности цвета, чтобы генераторы могли генерировать более согласованные образцы для разных масштабов [13].

Возможности использования при детальной реконструкции объектов по неполным данным, генерации карт местности и ситуаций с высокой детализацией, поддержки анализа разрушений, трещин, мелких дефектов.

Модель AttnGAN.

Рассмотренные выше модификации модели GAN демонстрируют ряд впечатляющих результатов, но у них есть главные недостатки: отсутствие чёткой детализации на уровне слов и невозможность генерации изображений высокого разрешения.

В качестве решения данной проблемы была предложена новая генеративно-состязательная нейросеть с вниманием (Attentional Generative Adversarial Network, AttnGAN),

которая относится к вниманию как к фактору обучения, что позволяет выделять слова для генерации фрагментов изображения.

Модель состоит из нескольких взаимодействующих нейросетей. Кодировщики текста (Text Encoder) и изображения (Image Encoder) векторизуют исходное текстовое описание и реальное изображение. В данном случае текст рассматривается в виде последовательности отдельных слов, представление которых обрабатывается совместно с представлением изображения, что позволяет сопоставить отдельные слова отдельным частям изображения.

Attentional Generative Network – самая большая сеть, состоящая из трех уровней. Каждый уровень порождает изображения все большего разрешения, от 64*64 до 256*256 пикселей, и результат работы на каждом уровне корректируется с помощью сетей внимания, которые несут в себе информацию о правильном расположении отдельных объектов сцены. Кроме того, результаты на каждом уровне проверяются тремя отдельно работающими дискриминаторами, которые оценивают реалистичность изображения и соответствие общему представлению о сцене.

Практическое значение состоит в создании изображений по сложным описаниям аварий и разрушений [14], уточнении деталей (таких как трещины, осадки, очаги возгорания и др.), построении синтетических данных для прогнозных моделей.

Модели ИИ, основанные на вариационных автокодировщиках

Вариационные автокодировщики (Variational Autoencoders, VAE) представляют собой особый класс генеративных моделей, использующих вероятностный подход к обучению, скрытых представлений данных. В отличие от классических автокодировщиков, которые просто сжимают и восстанавливают входные данные, VAE формируют распределение скрытых переменных, что предоставляет значительно большую гибкость при генерации новых данных и реконструкции изображений.

Большинство существующих методов генерации изображения по тексту нацелены на создание целостных изображений, которые не разделяют передний и задний план изображений, в результате чего объекты искажаются фоном. Более того, они обычно игнорируют взаимодополняемость различных видов генеративных моделей. Данное решение предлагает контекстно-зависимый подход к генерации изображения, который разделяет фон и передний план. Для этого используется взаимодополняющая связка вариационного автокодировщика и генеративно-состязательной нейросети.

VAE имеет более стабильный выход, чем GAN, однако он не подходит для генерации изображений высокого качества, так как генерируемые VAE изображения легко размываются. Чтобы исправить данный недостаток архитектура включает два компонента.

Контекстно-зависимый вариационный кодировщик (Conditional VAE, CVAE) используется для захвата основной компоновки и цвета, разделяя фон и передний план изображения.

GAN уточняет вывод CVAE с помощью состязательного обучения, которое восстанавливает потерянные детали и исправляет дефекты для создания реалистичного изображения.

VAE позволяет сгенерировать изображения, которых никто не видел.

Автоэнкодер состоит из двух соединенных нейронных сетей: модели энкодера (кодировщика) и модели декодера (декодировщика). Его цель – нахождение метода кодирования изображения в сжатую форму (скрытое пространство) таким образом, чтобы восстановленная версия была как можно ближе к входной. Энкодер – это сверточная нейронная сеть, а декодер – генеративная сверточная нейронная сеть.

Как правило, скрытое пространство, создаваемое энкодером, имеет мало элементов, то есть трудно предсказать распределение значений в этом пространстве. Значения разбросаны, и пространство обычно хорошо визуализируется в двухмерном представлении.

Это очень полезная особенность для систем сжатия (компрессии). Однако для генерации новых изображений эта разреженность – проблема, поскольку найти скрытое

значение, для которого декодер будет знать, как воспроизвести нормальное изображение, почти невозможно.

Вариационный автоэнкодер делает внутреннее пространство более предсказуемым, более непрерывным и менее разреженным. Заставляя скрытые переменные соответствовать нормальному распределению, VAE получают контроль над скрытым пространством.

Автокодировщик (autoencoder, также – автоассоциатор) – специальная архитектура искусственных нейронных сетей, позволяющая применять обучение без учителя при использовании метода обратного распространения ошибки. Простейшая архитектура автокодировщика – сеть прямого распространения, без обратных связей, наиболее схожая с перцептроном и содержащая входной слой, промежуточный слой и выходной слой. В отличие от перцептрона, выходной слой автокодировщика должен содержать столько же нейронов, сколько и входной слой.

Схема архитектуры автокодировщика представлена на рис. 2.




Рис. 2. Схема архитектуры автокодировщика (VAE)

При обучении нейронной сети необходимо получить выходной вектор x' наиболее близким к входному вектору x .

Автокодировщик – специальная архитектура искусственных нейронных сетей, позволяющая применять обучение без учителя при использовании метода обратного распространения ошибки. Простейшая архитектура автокодировщика – сеть прямого распространения, без обратных связей, наиболее схожая с перцептроном и содержащая входной слой, промежуточный слой и выходной слой. В отличие от перцептрона, выходной слой автокодировщика должен содержать столько же нейронов, сколько и входной слой.

Таким образом, нейросеть автоматически обучается выделять из входных данных общие признаки, которые кодируются в значениях весов искусственной нейронной сети. Так, при обучении сети на наборе различных входных изображений, нейросеть может обучиться самостоятельно.

VAE наиболее эффективны при задачах восстановления изображений, устранения шума, синтеза вариативных данных и анализа скрытых закономерностей. В контексте обеспечения безопасности при ЧС эта модель имеет важное значение: она помогает восстанавливать повреждённые изображения, моделировать потенциальные сценарии, анализировать параметры визуальных объектов и выявлять аномалии [15, 16].

Вывод

Проведённое исследование показало, что интеллектуальные технологии обработки графической информации играют ключевую роль в обеспечении безопасности в условиях чрезвычайных ситуаций. Современные методы глубокого обучения, включая свёрточные нейронные сети (CNN), генеративно состязательные сети (GAN) и вариационные автокодировщики (VAE), обладают широким спектром возможностей, позволяющим повышать эффективность анализа визуальных данных, поступающих из различных источников: беспилотных летательных аппаратов, систем видеонаблюдения, спутниковых комплексов и мобильной техники оперативных служб.

CNN продемонстрировали наибольшую эффективность в задачах классификации, сегментации и обнаружения объектов. Их устойчивость к шумам и вариативности условий делает их основой систем компьютерного зрения, применяемых для мониторинга обстановки, обнаружения пострадавших, локализации очагов возгорания [17], анализа разрушений и оценки рисков. CNN могут эффективно использоваться в реальном времени, что особенно важно для оперативных подразделений МЧС России.

GAN, благодаря своей генеративной природе, дополняют возможности CNN, обеспечивая улучшение качества изображений, моделирование различных сценариев, формирование синтетических обучающих данных и реконструкцию утраченных фрагментов изображений. Различные модификации GAN (DCGAN, StackGAN, FusedGAN, ChatPainter, StackGAN++, AttnGAN) позволяют гибко адаптировать модель под конкретные задачи: от генерации изображений по текстовому описанию до высокоточной реконструкции визуальных данных с применением механизмов внимания. Эти модели особенно ценны при недостатке данных, необходимости моделирования редких событий или создании учебных материалов для подготовки спасателей.

VAE представляют собой устойчивый и интерпретируемый инструмент восстановления изображений, устранения шума и анализа скрытых закономерностей. Способность формировать структурированное скрытое пространство делает VAE незаменимыми при реконструкции повреждённых снимков, выявлении аномалий и прогнозировании развития аварийных ситуаций. VAE особенно полезны в случаях, когда требуется стабильное и надёжное моделирование, а не максимальная фотореалистичность.

Результаты исследования подтверждают необходимость дальнейшего развития и внедрения глубинных нейросетевых технологий, что позволит существенно повысить готовность и эффективность реагирования на ЧС в самых разных условиях.

Список источников

1. Zhang X., Dahu W. Application of artificial intelligence algorithms in image processing // *Journal of Visual Communication and Image Representation*. 2019. Vol. 61. P. 42–49.
2. Лабинский А.Ю. Особенности использования нейронной сети для распознавания изображений // *Проблемы управления рисками в техносфере*. 2016. № 3 (39). С. 67–73.
3. Шкурат Д.Е., Матвеев А.В. Проблемы обнаружения пожара по видеоизображению: обзор исследований // *Природные и техногенные риски (физико-математические и прикладные аспекты)*. 2025. № 2 (54). С. 59–73.
4. Лабинский А.Ю. Особенности нейронных сетей, использующих методы глубокого обучения // *Научно-аналитический журнал «Вестник Санкт-Петербургского университета Государственной противопожарной службы МЧС России»*. 2021. № 4. С. 58–66.
5. Comprehensive review of artificial neural network applications to pattern recognition / O.I. Abiodun [et al.] // *IEEE access*. 2019. Vol. 7. P. 158820–158846.
6. Муаль М.Н.Б., Козырев Д.В. Применение сверточных нейронных сетей для обнаружения и распознавания изображений на основе самописного генератора // *Современные информационные технологии и ИТ-образование*. 2022. Т. 18. № 3. С. 507–515.
7. Локтев Д.А., Пролетарский А.В., Локтев А.А. Моделирование системы мониторинга объектов с использованием сверточной нейронной сети // *Промышленные АСУ и контроллеры*. 2020. № 9. С. 39–46.

8. Тарасов А.С., Никифоров М.Б., Бакамбис Н.И. Применение сверточных сегментационных нейронных сетей для экологического мониторинга земной поверхности // Известия Тульского государственного университета. Технические науки. 2021. № 6. С. 3–10.
9. Малахов Ю.А., Андросов А.А., Аверченков А.В. Анализ и применение генеративно-сопоставительных сетей для получения изображений высокого качества // Эргодизайн. 2020. № 4 (10). С. 167–176.
10. Synthetic Data generation using DCGAN for improved traffic sign recognition / C. Dewi [et al.] // Neural Computing and Applications. 2022. Vol. 34. №. 24. P. 21465–21480.
11. Modeling and simulating spatial extremes by combining extreme value theory with generative adversarial networks / Y. Boulaguiem [et al.] // Environmental Data Science. 2022. Vol. 1. P. e5.
12. GANsight Innovations: Generative Adversarial Networks for Innovative Medical Imaging / L. Chandana [et al.] // 2024 4th International Conference on Mobile Networks and Wireless Communications (ICMNWC). IEEE, 2024. P. 1–7.
13. Stackgan++: Realistic image synthesis with stacked generative adversarial networks / H. Zhang [et al.] // IEEE transactions on pattern analysis and machine intelligence. 2018. Vol. 41. № 8. P. 1947–1962.
14. Text-to-traffic generative adversarial network for traffic situation generation / Huo G. [et al.] // IEEE Transactions on Intelligent Transportation Systems. 2021. Vol. 23. № 3. P. 2623–2636.
15. Variational autoencoder anomaly-detection of avalanche deposits in satellite SAR imagery / S. Sinha [et al.] // Proceedings of the 10th International Conference on Climate Informatics. 2020. P. 113–119.
16. Wangiyana S. Flood Detection Using Variational Autoencoder in SAR Images // 2023 Signal Processing Symposium (SPSymposium). IEEE, 2023. P. 195–197.
17. Автоматизация процедур обнаружения лесных пожаров по результатам обработки видео / Д.В. Васильева [и др.] // Научно-аналитический журнал «Вестник Санкт-Петербургского университета государственной противопожарной службы МЧС России». 2023. № 4. С. 47–58.

References

1. Zhang X., Dahu W. Application of artificial intelligence algorithms in image processing // Journal of Visual Communication and Image Representation. 2019. Vol. 61. P. 42–49.
2. Labinskij A.Yu. Osobennosti ispol'zovaniya nejronnoj seti dlya raspoznavaniya izobrazhenij // Problemy upravleniya riskami v tekhnosfere. 2016. № 3 (39). S. 67–73.
3. SHkurat D.E., Matveev A.V. Problemy obnaruzheniya pozhara po videoizobrazheniyu: obzor issledovaniy // Prirodnye i tekhnogennye riski (fiziko-matematicheskie i prikladnye aspekty). 2025. № 2 (54). S. 59–73.
4. Labinskij A.Yu. Osobennosti nejronnyh setej, ispol'zuyushchih metody glubokogo obucheniya // Nauchno-analiticheskij zhurnal «Vestnik Sankt-Peterburgskogo universiteta Gosudarstvennoj protivopozharnoj sluzhby MCHS Rossii». 2021. № 4. S. 58–66.
5. Comprehensive review of artificial neural network applications to pattern recognition / O.I. Abiodun [et al.] // IEEE access. 2019. Vol. 7. P. 158820–158846.
6. Mual' M.N.B., Kozyrev D.V. Primenenie svertochnykh nejronnykh setej dlya obnaruzheniya i raspoznavaniya izobrazhenij na osnove samopisnogo generatora // Sovremennye informacionnye tekhnologii i IT-obrazovanie. 2022. T. 18. № 3. S. 507–515.
7. Loktev D.A., Proletarskij A.V., Loktev A.A. Modelirovanie sistemy monitoringa ob"ektov s ispol'zovaniem svertochnoj nejronnoj seti // Promyshlennyye ASU i kontroly. 2020. № 9. S. 39–46.
8. Tarasov A.S., Nikiforov M.B., Bakambis N.I. Primenenie svertochnykh segmentacionnykh nejronnykh setej dlya ekologicheskogo monitoringa zemnoj poverhnosti // Izvestiya Tul'skogo gosudarstvennogo universiteta. Tekhnicheskie nauki. 2021. № 6. S. 3–10.

9. Malahov Yu.A., Androsov A.A., Averchenkov A.V. Analiz i primeneniye generativno-sostyazatel'nyh setej dlya polucheniya izobrazhenij vysokogo kachestva // *Ergodizajn*. 2020. № 4 (10). S. 167–176.
10. Synthetic Data generation using DCGAN for improved traffic sign recognition / C. Dewi [et al.] // *Neural Computing and Applications*. 2022. Vol. 34. №. 24. P. 21465–21480.
11. Modeling and simulating spatial extremes by combining extreme value theory with generative adversarial networks / Y. Boulaguiem [et al.] // *Environmental Data Science*. 2022. Vol. 1. P. e5.
12. GANsight Innovations: Generative Adversarial Networks for Innovative Medical Imaging / L. Chandana [et al.] // 2024 4th International Conference on Mobile Networks and Wireless Communications (ICMNWC). IEEE, 2024. P. 1–7.
13. Stackgan++: Realistic image synthesis with stacked generative adversarial networks / H. Zhang [et al.] // *IEEE transactions on pattern analysis and machine intelligence*. 2018. Vol. 41. № 8. P. 1947–1962.
14. Text-to-traffic generative adversarial network for traffic situation generation / Huo G. [et al.] // *IEEE Transactions on Intelligent Transportation Systems*. 2021. Vol. 23. № 3. P. 2623–2636.
15. Variational autoencoder anomaly-detection of avalanche deposits in satellite SAR imagery / S. Sinha [et al.] // *Proceedings of the 10th International Conference on Climate Informatics*. 2020. P. 113–119.
16. Wangiyana S. Flood Detection Using Variational Autoencoder in SAR Images // 2023 Signal Processing Symposium (SPSymposium). IEEE, 2023. P. 195–197.
17. Avtomatizaciya procedur obnaruzheniya lesnyh pozharov po rezul'tatam obrabotki video / D.V. Vasil'eva [i dr.] // *Nauchno-analiticheskij zhurnal Vestnik Sankt-Peterburgskogo universiteta gosudarstvennoj protivopozharnoj sluzhby MCHS Rossii*". 2023. № 4. S. 47–58.

Информация о статье:

Статья поступила в редакцию: 18.08.2025; одобрена после рецензирования: 19.11.2025;
принята к публикации: 29.11.2025

The information about article:

The article was submitted to the editorial office: 18.08.2025; approved after review: 19.11.2025;
accepted for publication: 29.11.2025

Информация об авторах:

Лабинский Александр Юрьевич, доцент кафедры прикладной математики и безопасности информационных технологий Санкт-Петербургского университета ГПС МЧС России (196105, Санкт-Петербург, Московский пр., д. 149), кандидат технических наук, доцент, e-mail: labinskyi.a@igps.ru, <https://orcid.org/0000-0001-2735-4189>, SPIN-код: 8338-4230

Information about the authors:

Labinsky Alexander Yu., associate professor of the department of applied mathematics and information technologies security of Saint-Petersburg of State fire service of EMERCOM of Russia (196105, Saint-Petersburg, Moskovsky ave., 149), candidate of technical sciences, associate professor, e-mail: Labinsciy@yandex.ru, <https://orcid.org/0000-000>