

## ТЕХНИЧЕСКИЕ НАУКИ



УДК 004.032.26

### Удаление водяных знаков с изображений с использованием технологии глубокого обучения

А.А. Мищенко, А.Е. Шепило, И.А. Веденеев

Донской государственный технический университет, г. Ростов-на-Дону, Российская Федерация

#### Аннотация

Водяные знаки используются для защиты авторских прав и подтверждения подлинности изображений, однако в некоторых случаях необходимо восстановить оригинальное изображение без водяных знаков. Целью данной работы является разработка метода удаления водяных знаков с изображений с использованием архитектуры U-Net, выбранной именно благодаря её способности эффективно восстанавливать изображения с минимальными артефактами. В ходе исследования были выполнены следующие задачи: подготовка данных, разработка и обучение модели, оценка её эффективности. Эксперименты показали, что предложенная модель демонстрирует высокую точность и качество удаления водяных знаков по сравнению с традиционными методами. Результаты подтвердили перспективность использования глубокого обучения для решения данной задачи и могут быть полезны в различных областях, таких как журналистика, медицинская визуализация и криминалистика.

**Ключевые слова:** удаление водяных знаков, глубокое обучение, U-Net, обработка изображений, нейронная сеть, сегментация изображений, точность, артефакт, датасет, восстановление изображения

**Для цитирования.** Мищенко А.А., Шепило А.Е., Веденеев И.А. Удаление водяных знаков с изображений с использованием технологии глубокого обучения. *Молодой исследователь Дона*. 2024;9(4):17–21.

### Removing Watermarks from Images with the Help of Deep Learning Technology

Aleksandr A. Mishchenko, Alina E. Shepilo, Ivan A. Vedeneev

Don State Technical University, Rostov-on-Don, Russian Federation

#### Abstract

Watermarks are often used to protect intellectual property and confirm the authenticity of digital images. However, in some cases it is necessary to restore the original image without watermarks. The aim of this work is to develop a method for removing watermarks from images using the U-Net architecture, chosen precisely because of its ability to efficiently restore images with minimal artifacts. During the research, the following tasks were performed: data preparation, model development and training, and evaluation of its effectiveness. Experiments showed that the proposed model demonstrated high accuracy and quality of watermark removal compared to traditional methods. The results confirmed the potential of using deep learning to solve this problem. It can be useful in various fields such as journalism, medical imaging and criminology.

**Keywords:** watermark removal, deep learning, U-Net, image processing, neural network, image segmentation, accuracy, artifact, dataset, image restoration

**For citation.** Mishchenko AA, Shepilo AE, Vedeneev IA. Removing Watermarks from Images with the Help of Deep Learning Technology. *Young Researcher of Don*. 2024;9(4):17–21.

**Введение.** Удаление водяных знаков с изображений является важной задачей в области компьютерного зрения и обработки изображений. Водяные знаки часто используются для защиты авторских прав и подтверждения подлинности изображений, однако в некоторых случаях необходимо восстановить оригинальное изображение без водяных знаков. Это может быть важно для журналистики, медицинской визуализации, криминалистики и других областей, где качество изображения играет критическую роль. Цель данной работы заключается в разработке метода удаления водяных знаков с изображений с использованием архитектуры U-Net.

## Основная часть

**Традиционные методы удаления водяных знаков.** К основным традиционным методам удаления водяных знаков относятся:

1. Методы фильтрации. Использование фильтров, таких как медианный или гауссовский, для удаления или сглаживания водяных знаков может быть эффективным при небольших и малозаметных водяных знаках, но часто приводит к потере деталей изображения и оставлению артефактов [1].

2. Интерполяционные методы. Использование различных техник интерполяции, таких как билинейная или бикубическая интерполяция, для заполнения областей, занятых водяными знаками, также приводит к потере информации и может создавать заметные артефакты.

3. Морфологические операции. Применение таких морфологических операций, как эрозия и дилатация, для уменьшения видимости водяных знаков часто приводит к искажениям в структуре изображения [1].

Как видим, эффективность традиционных методов удаления водяных знаков достаточно низка. С развитием технологий глубокого обучения стало возможным применять более сложные и точные методы для решения этой задачи.

**Методы глубокого обучения.** Современные методы глубокого обучения продемонстрировали высокую способность воссоздавать оригинальные изображения с минимальными потерями качества. Ключевыми подходами в этой области являются:

1. Сверточные нейронные сети (CNN). Используются для извлечения признаков и восстановления изображения без водяных знаков. Примерами таких сетей могут служить архитектуры ResNet или U-Net, способные обучаться на большом количестве данных и восстанавливать мелкие детали изображения [1].

2. Генеративные состязательные сети (GAN). Состоят из двух нейронных сетей — генератора и дискриминатора, которые соревнуются друг с другом. Генератор пытается создать изображение без водяного знака, в то время как дискриминатор оценивает его реалистичность. Архитектура GAN показала высокую эффективность в задачах генерации изображений и удаления артефактов [2].

3. Автоэнкодеры. Представляют собой нейронные сети, состоящие из кодировщика и декодировщика, которые учатся представлять данные в сжатой форме и затем восстанавливать их. В контексте удаления водяных знаков автоэнкодеры могут использоваться для удаления нежелательных элементов из изображения [3-5].

Сравнение традиционных методов и методов глубокого обучения, включая U-Net, показывает значительное преимущество последних по таким параметрам, как:

- точность: методы глубокого обучения, особенно U-Net, демонстрируют высокую точность в удалении водяных знаков без заметных артефактов;
- сохранение деталей: нейронные сети глубокого обучения лучше сохраняют детали изображения по сравнению с традиционными методами, которые часто теряют информацию при фильтрации или интерполяции;
- обучаемость: в отличие от традиционных методов, модели глубокого обучения могут быть обучены на больших наборах данных для адаптации к различным типам водяных знаков и изображений.

**Базы данных и предобработка данных.** Для обучения и тестирования модели использовался датасет Watermarked / Not watermarked images [6] с водяными знаками и без них. Изображения нормализуются путем деления на 255, таким образом, нормализованные значения пикселей находятся в диапазоне от 0 (черный) до 1 (белый), что упрощает обучение модели, так как большинство алгоритмов машинного обучения лучше работают с данными в ограниченном диапазоне. Сопоставление имен файлов водяных знаков и оригинальных изображений позволяет создать соответствующие пары для обучения. Для обучения данной модели мы используем датасет из 2 5000 изображений.

**Архитектура модели U-Net** — это тип сверточной нейронной сети, который был разработан для задач сегментации изображений, но также доказал свою эффективность в удалении водяных знаков. Ключевые особенности U-Net:

- симметричная архитектура: U-Net имеет структуру с нисходящей (энкодер) и восходящей (декодер) частями, что позволяет эффективно захватывать и восстанавливать пространственную информацию;
- скайпы соединения: важной особенностью U-Net являются скайпы соединения между соответствующими уровнями энкодера и декодера, которые помогают сохранять высокоуровневые признаки и улучшать качество восстановления изображения;
- детальное восстановление: благодаря своей архитектуре U-Net может восстанавливать мелкие детали изображения и минимизировать артефакты [5, 7].

Архитектура U-Net изображена на рис. 1. Входное изображение проходит через несколько уровней сверток и пулинга (энкодер), а затем восстанавливается через уровни апсемплинга и сверток (декодер) с использованием скайп-соединений.

Апсемплинг (от англ. “upsampling”) — это процесс увеличения разрешения изображения, который часто используется в нейронных сетях для восстановления пространственных характеристик изображения после того, как они были уменьшены. В контексте U-Net, апсемплинг выполняется путем применения слоев, таких как UpSampling2D или Conv2DTranspose. Эти слои увеличивают размер изображения, что позволяет модели восстанавливать детали и структуру исходного изображения. В нашей модели используются пять уровней энкодера и четыре уровня декодера. В таблице 1 представлены характеристики всех уровней.

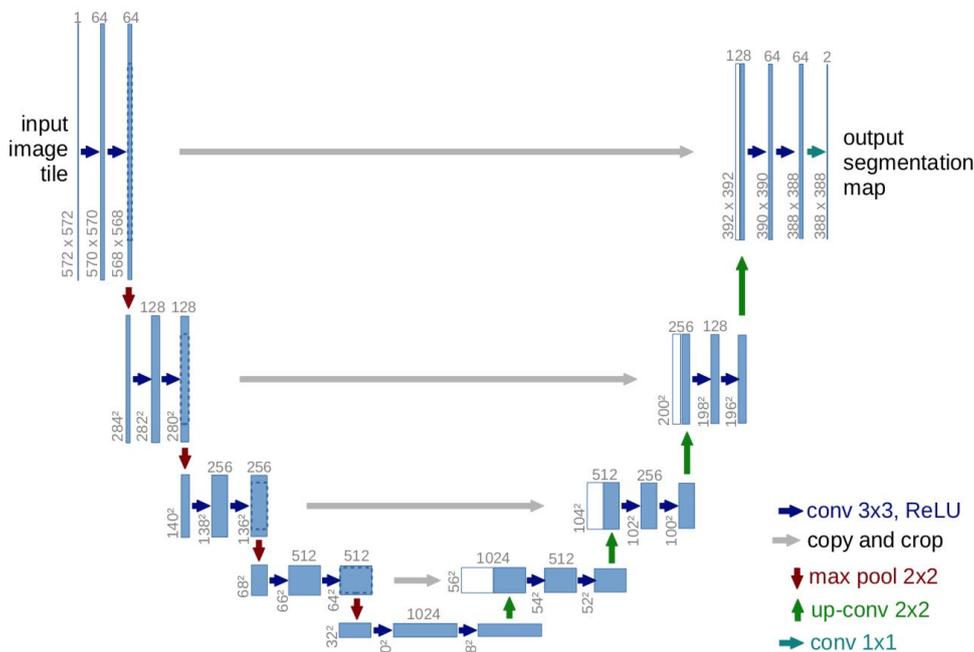


Рис. 1 Архитектура U-Net [7]

Таблица 1

Архитектура реализованной модели U-Net

Уровень	Тип слоя	Параметры слоя
Input	Input	(img_x, img_y, 3)
Encoder 1	Conv2D	64 фильтра, (3, 3), ReLU, same padding
	Conv2D	64 фильтра, (3, 3), ReLU, same padding
	MaxPooling2D	(2, 2)
Encoder 2	Conv2D	128 фильтра, (3, 3), ReLU, same padding
	Conv2D	128 фильтра, (3, 3), ReLU, same padding
	MaxPooling2D	(2, 2)
Encoder 3	Conv2D	256 фильтра, (3, 3), ReLU, same padding
	Conv2D	256 фильтра, (3, 3), ReLU, same padding
	MaxPooling2D	(2, 2)
Encoder 4	Conv2D	512 фильтра, (3, 3), ReLU, same padding
	Conv2D	512 фильтра, (3, 3), ReLU, same padding
	MaxPooling2D	(2, 2)
Bottleneck	Conv2D	1024 фильтра, (3, 3), ReLU, same padding
	Conv2D	1024 фильтра, (3, 3), ReLU, same padding
Decoder 1	UpSampling2D	(2, 2)
	concatenate	axis=3
	Conv2D	512 фильтра, (3, 3), ReLU, same padding
Decoder 2	Conv2D	512 фильтра, (3, 3), ReLU, same padding
	UpSampling2D	(2, 2)
	concatenate	axis=3
	Conv2D	256 фильтра, (3, 3), ReLU, same padding
	Conv2D	256 фильтра, (3, 3), ReLU, same padding

Decoder 3	UpSampling2D	(2, 2)
	concatenate	axis=3
	Conv2D	128 фильтра, (3, 3), ReLU, same padding
	Conv2D	128 фильтра, (3, 3), ReLU, same padding
Decoder 4	UpSampling2D	(2, 2)
	concatenate	axis=3
	Conv2D	64 фильтра, (3, 3), ReLU, same padding
	Conv2D	64 фильтра, (3, 3), ReLU, same padding
Output	Conv2D	3 фильтра, (1, 1), sigmoid activation

**Эксперименты и результаты** Эксперименты были проведены с использованием наборов данных, разделенных на тренировочные и валидационные выборки. Модель U-Net была обучена на протяжении 100 эпох с использованием батчей по 55 изображений.

Батчи (от англ. “batches”) — это небольшие подмножества данных, используемые при обучении нейронных сетей. Вместо того чтобы обучать модель на всем наборе данных за один раз, данные разбиваются на более мелкие части — батчи. Это позволяет ускорить процесс обучения и стабилизировать его, так как модель обновляет свои параметры после каждой обработки батча, а не после обработки всего набора данных.

В процессе обучения отслеживались значения функции потерь как на тренировочной, так и на валидационной выборках. На графике, представленном на рис. 2, видно, что значение функции потерь значительно уменьшилось в первые несколько эпох, что указывает на быстрое улучшение модели.

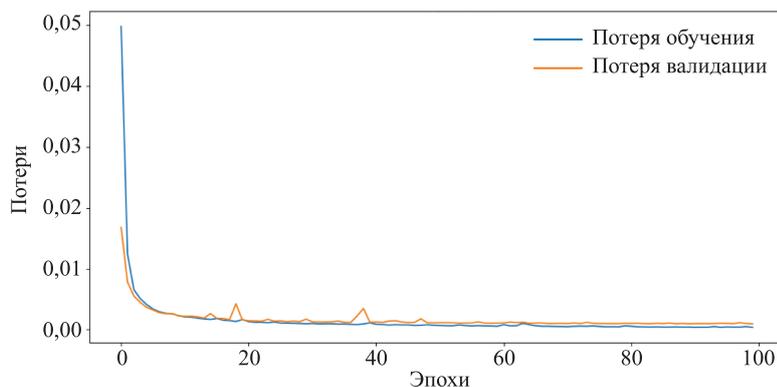


Рис. 2. График функции потерь

По мере продолжения обучения значения функции потерь стабилизировались, демонстрируя устойчивую производительность модели. Это указывает на то, что модель достигла состояния, близкого к оптимальному, и не демонстрирует признаков переобучения. Результат после завершения обучения модели можно увидеть на рис. 3.



Рис. 3. Результат выполнения модели

Для оценки качества работы модели были использованы две основные метрики:

– SSIM (Structural Similarity Index Measure) — эта метрика измеряет структурное сходство между исходным изображением и изображением после удаления водяного знака. Значение SSIM близкое к 1 указывает на высокое качество восстановленного изображения. В данном эксперименте модель достигла значения SSIM равному 0.879, что говорит о высоком качестве восстановления;

– MSE (Mean Squared Error) — эта метрика измеряет среднеквадратичную ошибку между исходным изображением и изображением после удаления водяного знака. Низкое значение MSE указывает на малую разницу между этими изображениями. Значение MSE равное 0.0072 демонстрирует, что модель способна точно восстанавливать исходное изображение после удаления водяного знака.

**Заключение** Предложенный метод удаления водяных знаков с использованием архитектуры U-Net демонстрирует высокую эффективность и точность, превосходя традиционные методы. Модель U-Net не только успешно удаляет водяные знаки, но и восстанавливает изображение с минимальными потерями качества. Удаление водяных знаков позволяет использовать фотографии без нежелательных пометок, улучшая качество публикаций и соблюдая права на использование изображений.

Точные и четкие изображения без артефактов необходимы для правильной диагностики и лечения. Предложенный метод обеспечивает высокое качество восстановления медицинских изображений. Восстановление оригинальных изображений без артефактов важно для анализа и доказательной базы при расследованиях. Модель U-Net позволяет получать изображения высокого качества, что может быть полезно в криминалистике.

#### Список литературы

1. Шолле Ф. *Глубокое обучение с R и Keras*. Яценкова В.С. (пер.). Москва: ДМК Пресс; 2023. 646 с.
2. Фостер Д. *Генеративное глубокое обучение. Творческий потенциал нейронных сетей*. Киселев А. (пер.). Санкт-Петербург: Питер; 2020. 336 с.
3. Малахов Ю.А., Андросов А.А., Аверченков А.В. Анализ и применение генеративно-сопоставительных сетей для получения изображения высокого качества. *Эргодизайн*. 2020;(4(10):167–176. <https://doi.org/10.30987/2658-4026-2020-4-167-176>
4. Николенко С.И., Кадурич А.А., Архангельская Е.О. *Глубокое обучение. Погружение в мир нейронных сетей*. Санкт-Петербург: Питер; 2018. 480 с.
5. Ватъян А.С., Гусарова Н.Ф., Добренко Н.В. *Системы Искусственного Интеллекта*. Санкт-Петербург: Университет ИТМО; 2022. 186 с. URL: <https://books.ifmo.ru/file/pdf/3142.pdf> (дата обращения: 12.05.2024).
6. Pollano F. *Watermarked / Not watermarked images* URL: <https://www.kaggle.com/datasets/felicepollano/watermarked-not-watermarked-images> (дата обращения: 03.05.2024).
7. Мазепов С. *Семантическая сегментация на основе архитектуры U-net и определения расстояния между объектами*. URL: <https://habr.com/ru/articles/746842/?amp&amp> (дата обращения: 05.05.2024).

#### Об авторах:

**Александр Александрович Мищенко**, студент кафедры компьютерная безопасность информационных систем Донского государственного технического университета (344003, РФ, г. Ростов-на-Дону, пл. Гагарина, 1), [thecludys@gmail.com](mailto:thecludys@gmail.com)

**Алина Евгеньевна Шепило**, студент кафедры компьютерная безопасность информационных систем Донского государственного технического университета (344003, РФ, г. Ростов-на-Дону, пл. Гагарина, 1), [shepiloali@gmail.com](mailto:shepiloali@gmail.com)

**Иван Алексеевич Веденев**, студент кафедры компьютерная безопасность информационных систем Донского государственного технического университета (344003, РФ, г. Ростов-на-Дону, пл. Гагарина, 1), [vanavedeneev@gmail.com](mailto:vanavedeneev@gmail.com)

**Конфликт интересов:** авторы заявляют об отсутствии конфликта интересов.

**Все авторы прочитали и одобрили окончательный вариант рукописи.**

#### About the Authors:

**Aleksandr A. Mishchenko**, Student of the Department of Computer Security of Information Systems, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, RF), [thecludys@gmail.com](mailto:thecludys@gmail.com)

**Alina E. Shepilo**, Student of the Department of Computer Security of Information Systems, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, RF), [shepiloali@gmail.com](mailto:shepiloali@gmail.com)

**Ivan A. Vedenev**, Student of the Department of Computer Security of Information Systems, Don State Technical University (1, Gagarin Sq., Rostov-on-Don, 344003, RF), [vanavedeneev@gmail.com](mailto:vanavedeneev@gmail.com)

**Conflict of Interest Statement:** the authors do not have any conflict of interest.

**All authors have read and approved the final manuscript.**