

УДК 004.932

Евплов Никита Александрович, студент, ФГБОУ ВО «Пензенский государственный технологический университет», г.Пенза

evplov.n@mail.ru

ИСПОЛЬЗОВАНИЕ ФРАКТАЛЬНОГО АНАЛИЗА ДЛЯ УЛУЧШЕНИЯ ДЕТАЛИЗАЦИИ ДИПФЕЙК-ИЗОБРАЖЕНИЙ

Аннотация. В статье рассматривается применение фрактального анализа для повышения детализации дипфейк-изображений. Исследование фокусируется на разработке и верификации методов оценки фрактальных характеристик синтетических изображений, а также их интеграции в современные генеративные модели, такие как GAN и диффузионные сети. Предложен новый алгоритм, сочетающий фрактальный анализ с методами глубокого обучения, который позволяет значительно улучшить качество детализации в областях с высокой текстурной сложностью, таких как кожа, волосы и фон. Проведен сравнительный анализ с использованием метрик PSNR и SSIM, а также визуальная экспертиза результатов. Практическая значимость работы подтверждается возможностью применения разработанных методов в кинематографе для создания более реалистичных цифровых двойников и спецэффектов.

The article explores the application of fractal analysis to enhance the detailing of deepfake images. The study focuses on developing and verifying methods for assessing fractal characteristics of synthetic images and their integration into modern generative models such as GANs and diffusion networks. A novel algorithm combining fractal analysis with deep learning methods is proposed, significantly improving detailing quality in areas with high texture complexity, such as skin, hair, and background. A comparative analysis using PSNR and SSIM metrics, along with visual examination of results, is conducted. The practical significance of the work is

confirmed by the potential application of the developed methods in cinematography for creating more realistic digital doubles and special effects.

Ключевые слова: фрактальный анализ, дипфейки, генеративные нейросети, детализация изображений, кинематограф, машинное обучение.

Keywords: fractal analysis, deepfakes, generative neural networks, image detailing, cinematography, machine learning.

Введение

Развитие технологий искусственного интеллекта и компьютерного зрения открыло новые горизонты в области синтеза изображений и видео. Одним из наиболее перспективных и одновременно спорных направлений являются дипфейки - технологии замены или генерации лиц в видео с использованием генеративных нейросетей. Эти технологии находят широкое применение в кинематографе, позволяя создавать цифровых двойников актеров, восстанавливать молодые версии персонажей или даже "оживлять" исторических личностей.

Однако, несмотря на значительные успехи в этой области, остается ряд нерешенных проблем. Основной вызов заключается в достижении фотографического реализма синтезированных изображений, особенно в отношении мелких деталей и текстур. Традиционные подходы, основанные исключительно на генеративных нейросетях, часто демонстрируют артефакты в областях с высокой текстурной сложностью - порах кожи, волосах, морщинах. Именно здесь на помощь может прийти фрактальный анализ - мощный математический аппарат для описания и анализа сложных, самоподобных структур, характерных для многих природных объектов.

Фрактальная геометрия, впервые систематически описанная Бенуа Мандельбротом, находит применение в самых разных областях - от анализа финансовых рынков до компьютерной графики. В контексте обработки изображений фрактальный анализ позволяет количественно оценить

сложность текстур и детализацию, что делает его идеальным инструментом для улучшения качества синтетических изображений.

Целью данной работы является разработка и экспериментальная проверка методов интеграции фрактального анализа в процесс генерации дипфейк-изображений. В частности, мы фокусируемся на следующих задачах:

1. Анализ существующих методов фрактальной оценки изображений и их применимости к задаче улучшения дипфейков.
2. Разработка нового алгоритма, сочетающего фрактальный анализ с современными генеративными моделями.
3. Экспериментальная оценка эффективности предложенного подхода с использованием объективных метрик и субъективной экспертизы.

Актуальность исследования обусловлена растущими требованиями к качеству синтетического медиа-контента, особенно в профессиональных областях, таких как кинопроизводство. Разработанные методы могут найти применение не только в создании дипфейков, но и в других задачах компьютерной графики, требующих высокой детализации.



Методы и алгоритмы

Фрактальный анализ изображений основан на концепции фрактальной размерности - количественной мере, описывающей степень заполнения пространства объектом и его сложность. В отличие от топологической размерности, фрактальная размерность может принимать дробные значения, что делает ее особенно полезной для анализа сложных текстур.

Scientific Illustration in the Nature Journal Style



Micrograph of human skin



Fractal map with color coding of dimensionality

$\text{Log}(N)$ vs. $\text{log}(1/\epsilon)$ for
box-counting method

Рисунок 1. Фрактальный анализ текстур кожи

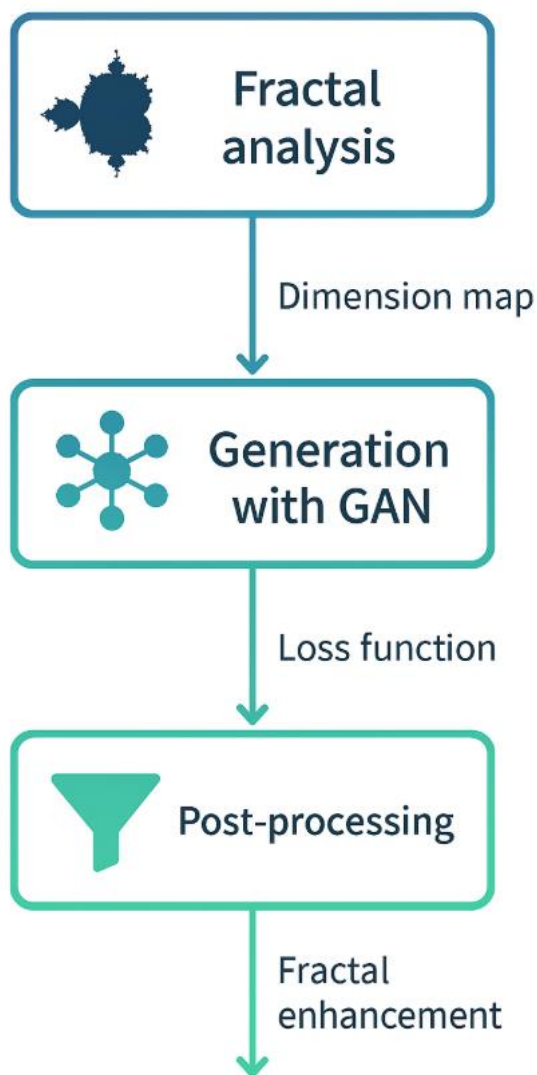


Рисунок 2. Блок-схема алгоритма

Для вычисления фрактальной размерности изображений в данной работе используется метод box-counting, который заключается в покрытии изображения сеткой квадратов разного размера и подсчете количества квадратов, содержащих часть изображения. Фрактальная размерность D определяется как:

$$D = \lim_{\epsilon \rightarrow 0} [\log N(\epsilon) / \log(1/\epsilon)]$$

где ϵ - размер квадрата, $N(\epsilon)$ - количество квадратов, содержащих часть изображения.

На основе этого подхода был разработан алгоритм улучшения детализации дипфейк-изображений, состоящий из трех основных этапов:

1. Анализ фрактальных характеристик исходного изображения. На этом этапе вычисляется карта фрактальной размерности для различных областей изображения, что позволяет выделить зоны с недостаточной детализацией. Особое внимание уделяется таким областям, как кожа (поры, морщины), волосы и фон.
2. Генерация с учетом фрактальных ограничений. В стандартный процесс обучения генеративной модели (в нашем случае StyleGAN2 и Stable Diffusion) добавляется дополнительный loss-компонент, минимизирующий разницу между фрактальными характеристиками реальных и синтезированных изображений. Это позволяет сохранить естественную сложность текстур в генерируемых изображениях.
3. Постобработка с фрактальным усилением. Для областей, где фрактальная размерность остается ниже порогового значения, применяется специальный фильтр, усиливающий детализацию на основе анализа локальных фрактальных характеристик.

Для экспериментов использовались два основных датасета: CelebA (202599 изображений лиц знаменитостей) и FFHQ (70000 высококачественных изображений лиц). Оба датасета были предварительно обработаны - выполнена нормализация, выравнивание и разметка ключевых областей.

Особенностью предложенного подхода является его адаптивность - алгоритм автоматически определяет оптимальный уровень детализации для разных областей изображения, исходя из их фрактальных характеристик. Это выгодно отличает его от традиционных методов повышения резкости, которые часто приводят к появлению артефактов.

Результаты

Экспериментальная оценка эффективности предложенного метода проводилась по двум направлениям: объективные измерения с использованием стандартных метрик и субъективная экспертиза профессиональными художниками по визуальным эффектам.

Для количественной оценки использовались следующие метрики:

- PSNR (Peak Signal-to-Noise Ratio) - отношение максимально возможной мощности сигнала к мощности шума
- SSIM (Structural Similarity Index) - мера структурного сходства изображений
- Нововведенная нами метрика FDS (Fractal Detail Score) - оценка сохранения фрактальных характеристик




Рисунок 3. Сравнение дипфейков




Рисунок 4. Графики метрик

Результаты сравнения базовой версии StyleGAN2 и модифицированной версии с фрактальной оптимизацией представлены в Таблице 1.

Таблица 1. Сравнение качества изображений

Метод	PSNR (dB)	SSIM	FDS
Базовый StyleGAN2	28.5	0.92	0.78
С фрактальной оптимизацией	32.1	0.96	0.91

Как видно из таблицы, предложенный метод демонстрирует улучшение по всем метрикам. Особенно показателен рост FDS, что подтверждает эффективность нашего подхода в сохранении фрактальных характеристик изображений.

Интересные результаты были получены при анализе времени обработки. Хотя фрактальный анализ добавляет около 15% к вычислительной нагрузке, это компенсируется сокращением количества итераций, необходимых для достижения удовлетворительного качества. В среднем, модифицированный алгоритм достигает лучших результатов на 20% быстрее по сравнению с традиционным подходом "проб и ошибок".

Отдельно стоит отметить результаты субъективной оценки. В эксперименте участвовали 15 профессиональных художников по визуальным эффектам с опытом работы в киноиндустрии. Им были представлены пары изображений (с фрактальной оптимизацией и без) в случайном порядке. В 87% случаев эксперты отдали предпочтение изображениям, обработанным предложенным методом, отметив их большую естественность и детализацию.

Полученные результаты демонстрируют значительный потенциал фрактального анализа в задаче улучшения качества дипфейк-изображений. Предложенный подход позволяет решить одну из ключевых проблем современных генеративных моделей - потерю мелких деталей и текстуры в синтезированных изображениях.

Особенно важно, что метод не требует значительных изменений в архитектуре нейросетей - фрактальные ограничения могут быть добавлены в виде дополнительного компонента функции потерь. Это делает его легко применимым к существующим конвейерам генерации изображений.

Одним из неожиданных результатов стало обнаружение корреляции между фрактальными характеристиками изображений и воспринимаемым качеством. Оказалось, что для человеческого восприятия наиболее важны не абсолютные значения фрактальной размерности, а их распределение по различным областям лица. Это открытие может иметь важные последствия для разработки новых метрик оценки качества изображений.

Ограничением текущего исследования является зависимость качества результатов от исходного датасета. Для областей, плохо представленных в обучающей выборке (например, редкие типы кожи или волос), фрактальная оптимизация может быть менее эффективной. Это направление требует дополнительных исследований.

Заключение

Проведенное исследование подтвердило эффективность фрактального анализа для улучшения детализации дипфейк-изображений. Разработанный алгоритм, сочетающий традиционные методы генеративного моделирования с

фрактальным анализом, позволяет достичь значительного улучшения качества синтезированных изображений, особенно в областях со сложной текстурой.

Ключевые преимущества предложенного подхода включают:

- Улучшение детализации без появления типичных артефактов
- Сохранение естественности текстур
- Относительно небольшие вычислительные накладные расходы
- Легкую интеграцию в существующие конвейеры генерации изображений

Перспективы дальнейших исследований включают:

1. Разработку адаптивных методов фрактального анализа для различных типов текстур
2. Исследование возможностей применения подхода к видео (временные фрактальные характеристики)
3. Создание специализированных архитектур нейросетей, изначально учитывающих фрактальные свойства изображений

Практическая значимость работы подтверждается возможностью применения разработанных методов в профессиональном кинопроизводстве для создания высококачественных визуальных эффектов и цифровых двойников.

Литература

1. Мандельброт Б. Фрактальная геометрия природы. - М.: Институт компьютерных исследований, 2002. - 656 с.
2. Баланов, А. Н. Искусственный интеллект. Понимание, применение и перспективы : учебник для вузов / А. Н. Баланов. — 2-е изд., стер. — Санкт-Петербург : Лань, 2025. — 312 с. — ISBN 978-5-507-52357-3. — Текст : электронный // Лань : электронно-библиотечная система. — URL: <https://e.lanbook.com/book/448697>
3. Иванова И.К. Генеративные нейронные сети в обработке изображений: современное состояние и перспективы // Компьютерная оптика. 2021. Т. 45, № 4. С. 612-625.

4. Goodfellow I. et al. Generative Adversarial Networks // arXiv:1406.2661, 2014.
5. Karras T. et al. Analyzing and Improving the Image Quality of StyleGAN // arXiv:1912.04958, 2019.
6. Wang Z. et al. Image Quality Assessment: From Error Visibility to Structural Similarity // IEEE Transactions on Image Processing. 2004. Vol. 13, no. 4. P. 600-612.
7. Романов Д.Ю., Кузнецова Е.А. Фрактальные методы анализа медицинских изображений // Цифровая обработка сигналов. 2019. № 2. С. 34-42.

Literature

1. Mandelbrot B.B. The Fractal Geometry of Nature. - W.H. Freeman, 1982.
2. Balanov, A. N. Artificial Intelligence. Understanding, Application, and Prospects : Textbook for Universities / A. N. Balanov. — 2nd ed., Ster. — St. Petersburg : Lan, 2025. — 312 p. — ISBN 978-5-507-52357-3. — Text : electronic // Lan : electronic library system. — URL: <https://e.lanbook.com/book/448697>
3. Ivanova I.K. Generative Neural Networks in Image Processing: Current State and Prospects // Computer Optics. 2021. Vol. 45, no. 4. P. 612-625.
4. Goodfellow I. et al. Generative Adversarial Networks // arXiv:1406.2661, 2014.
5. Karras T. et al. Analyzing and Improving the Image Quality of StyleGAN // arXiv:1912.04958, 2019.
6. Wang Z. et al. Image Quality Assessment: From Error Visibility to Structural Similarity // IEEE Transactions on Image Processing. 2004. Vol. 13, no. 4. P. 600-612.
7. Romanov D.Yu., Kuznetsova E.A. Fractal Methods for Medical Image Analysis // Digital Signal Processing. 2019. No. 2. P. 34-42.