

МЕТОДЫ ЭКСПЕРИМЕНТАЛЬНОЙ ФИЗИКИ

УДК 681.772; 004.92

СВЕРХРАЗРЕШЕНИЕ ИЗОБРАЖЕНИЙ
В ОДНОПИКСЕЛЬНОЙ ВИЗУАЛИЗАЦИИ С ПОМОЩЬЮ
ГЕНЕРАТИВНЫХ СОСТЯЗАТЕЛЬНЫХ СЕТЕЙ

Д. В. Бабухин, А. А. Реутов, Д. В. Сыч

Визуализация физических объектов с помощью однопиксельных камер – это активно развивающееся направление на стыке оптики и вычислительной математики. Алгоритмы восстановления изображений, используемые в однопиксельных камерах, обычно дают невысокое разрешение из-за практических ограничений на реалистичные вычислительные ресурсы. В данной работе мы демонстрируем увеличение разрешения изображений, получаемых в однопиксельной визуализации, с помощью генеративно-состязательной нейронной сети, и показываем ее применение на примере рентгеновских изображений грудной клетки из набора MedMNIST.

Ключевые слова: однопиксельная визуализация, восстановление изображений, генеративные состязательные сети, сверхразрешение.

Введение. Однопиксельная визуализация является перспективным методом построения изображений в задачах, где использование многопиксельных матриц нецелесообразно или технически сложно. Достоинства этого метода были показаны на многочисленных примерах, в частности, получении мультиспектральных изображений [1], трехмерных изображений [2, 3], изображений в рентгеновском диапазоне [4, 5] и ближнем инфракрасном диапазоне на однофотонном уровне [6]. Отличительной особенностью однопиксельной визуализации по сравнению с традиционными методами визуализации является использование пространственно неоднородного модулированного освещения объекта и однопиксельного детектора, измеряющего интенсивность отраженного от объекта излучения при заданной модуляции [7, 8]. Далее изображение алгоритмически

ФИАН, 119991 Россия, Москва, Ленинский пр-т, 53; e-mail: dv.babukhin@gmail.com.

восстанавливается из набора величин интенсивности, измеренных для разных видов пространственной модуляции освещения [9–11].

В последние годы в качестве алгоритмической части однопиксельной визуализации стали применяться методы сжатого сэмплирования [12, 13] и машинного обучения [14–16], что позволило значительно повысить эффективность однопиксельной визуализации в различных задачах [12–16]. Процесс восстановления изображения из измеренных значений интенсивности является вычислительно-ресурсоемкой задачей, сложность которой быстро растёт с увеличением размера изображения [17, 18]. В частности, нейросетевые методы подразумевают обучение нейронной сети восстановлению изображения из отсчётов интенсивностей. Увеличение размера конечного изображения требует увеличения размера нейронной сети и существенно усложняет процесс обучения нейронной модели. Восстановление изображения с малым разрешением и последующее увеличение разрешения может быть более эффективным подходом, чем непосредственно восстановление изображения с высоким разрешением. Кроме того, разделение всей задачи на два этапа (первичное восстановление изображения с низким разрешением и последующее увеличение разрешения) даёт возможность использовать на каждом этапе как метод сжатого сэмплирования, так и нейросетевые методы в зависимости от того, какой алгоритм показывает лучшие результаты и работает быстрее в каждом конкретном случае.

В этой работе мы исследуем возможность повышения разрешения изображений, получаемых в однопиксельной визуализации, за счет применения специально созданной генеративно-сопоставительной нейронной сети. Получение итогового изображения может быть разделено на два этапа. На первом этапе создается первичное изображение в низком разрешении, которое на втором этапе можно увеличить посредством решения задачи сверхразрешения – создания аналога целевого изображения с большим числом пикселей по сравнению с первичным изображением. В последние годы для сверхразрешения изображений стали активно применяться нейронные сети [19], однако в задаче однопиксельной визуализации такой подход до сих пор не использовался. Мы обучаем генеративную нейронную сеть на наборе данных, содержащем как восстановленные изображения с низким разрешением, так и соответствующие им изображения с высоким разрешением. Использование такого набора данных позволяет нам обучить нейронную сеть выполнять сверхразрешение изображений с учётом неточности в восстановлении изначальных изображений с камеры и влияние шумов при детектировании.

Однопиксельная визуализация. Однопиксельная визуализация представляет собой метод получения изображения объекта посредством измерения отраженного света с по-

мощью одиночного детектора и последующего алгоритмического восстановления изображения из результатов измерений. Для того чтобы осуществить такое восстановление изображения, падающий на объект свет предварительно модулируется с помощью набора паттернов, а собранные детектором значения интенсивностей (по одному значению на один паттерн) используются для численного восстановления. Математически, процесс работы однопиксельной камеры описывается уравнением

$$S = P\tilde{x}, \quad (1)$$

где S – вектор интенсивностей, измеренных детектором, P – вектор векторизованных матриц паттернов, модулирующих падающий на объект свет, и \tilde{x} – векторизованное матричное представление изображения целевого объекта. Для восстановления изображения объекта необходимо решить обратную задачу вида

$$\tilde{x} = P^{-1}S. \quad (2)$$

Подобная задача решается точно (т. е. нахождением обратной матрицы P) только при отсутствии шумов в измеренных отсчётах и при использовании количества отсчётов, равного количеству пикселей в изображении. На практике, из-за неидеальности работы аппаратуры, а также сложности поиска обратной матрицы паттернов, применяются методы, позволяющие восстанавливать изображение с использованием меньшего, чем число пикселей, количества отсчётов (количества использованных паттернов). Первым семейством таких методов являются методы, основанные на сжатом сэмплеировании [12, 13, 20, 21], которые представляют собой оптимизационное решение задачи (2), регуляризованной функцией ошибки L_1

$$L_1 = \frac{1}{WH} \sum_{i=1}^H \sum_{j=1}^W |\tilde{x}_{i,j}|, \quad (3)$$

которая позволяет решать задачу восстановления при помощи выпуклой оптимизации. Здесь W и H – ширина и высота генерируемого изображения. Однако алгоритмы на основе сжатого сэмплеирования требуют значительных затрат времени на восстановление изображения. В качестве альтернативы таким алгоритмам в последние годы активно развиваются нейросетевые подходы к восстановлению изображений с однопиксельной камеры [14–16], которые превосходят методы сжатого сэмплеирования по точности восстановленного изображения и скорости восстановления изображения.

В численной симуляции в нашей работе для восстановления изображения из отсчётов с однопиксельной камеры мы используем сверточную генеративную состязательную

сеть, архитектура которой описана в [22]. Мы используем 64 паттерна для восстановления изображений размером 28 на 28, т. е. количество паттернов равно 8.16% от числа пикселей в изображении объекта. Восстановление изображений выполнено для различных уровней шума, который параметризуется величиной α , а модель шума имеет вид

$$S_{\text{noise}} = \alpha \langle S \rangle \vec{u}, \quad (4)$$

где \vec{u} – вектор со случайными элементами, распределенными равномерно в интервале от 0 до 1, $\langle S \rangle$ – среднее значение интенсивности для вектора отсчётов с однопиксельной камеры. Полученное изображение впоследствии используется для сверхразрешения.

Сверхразрешение изображений в однопиксельной визуализации. Пусть изображение с высоким разрешением X представляет собой матрицу из N^2 пикселей. Из этого изображения можно получить изображение с низким разрешением \tilde{x} , представляющее собой матрицу из $(sN)^2$ пикселей, где s принимает значения от 0 до 1:

$$\tilde{x} = D(X), \quad (5)$$

где D – сжимающее преобразование. При таком преобразовании часть информации о структуре изображения теряется, и преобразование необратимо: одному итоговому изображению \tilde{x} могут соответствовать несколько изначальных изображений X . Таким образом, нахождение изображения с высоким разрешением из изображения с низким разрешением

$$X = D^{-1}(\tilde{x}), \quad (6)$$

является некорректно поставленной задачей, т. е. задачей, не имеющей однозначного решения. Поэтому возможно найти только отображение, осуществляющее решение задачи в соответствии с каким-либо требованием (критерием).

Процедура нахождения такого отображения изображения низкого разрешения \tilde{x} в изображение высокого разрешения X представляет собой оптимизационную задачу по поиску такого изображения, которое, с одной стороны, при уменьшении разрешения даёт целевое изображение низкого разрешения, а с другой стороны, удовлетворяет какому-то критерию в пространстве своей размерности – например, требованию разреженности или же визуальной правдоподобности. Одним из путей решения задачи нахождения такого отображения является обучение нейронной сети. Пусть у нас имеется набор пар изображений (\tilde{x}_i, X_i) , где \tilde{x}_i – изображение с низким разрешением, а X_i – соответствующее изображение с высоким разрешением, и пусть мы обучаем нейронную сеть $N(\tilde{x}, \theta)$,

где θ – параметры нейронной сети. Процесс обучения нейронной сети представляет собой минимизацию заданной функции ошибки L

$$\hat{\theta} = \operatorname{argmin}_{\theta} L(X, N(\tilde{x}, \theta)). \quad (7)$$

Функция L содержит в себе требования к структуре восстанавливаемых изображений.

Для сверхразрешения изображения, восстановленного из отсчётов с однопиксельной камеры, мы используем генеративную состязательную сеть, архитектура сети приведена на рис. 1. Генеративная нейронная сеть включает в себя две нейросети. Сеть-генератор $G(\tilde{x})$ принимает на вход изображение низкого разрешения \tilde{x} и генерирует изображение с высоким разрешением. Сеть-дискриминатор $D(G(\tilde{x}))$ принимает на вход изображение высокого разрешения и генерирует число – вероятность того, что входное изображение было сгенерировано сетью-генератором.

Процесс обучения нейронной сети решению задачи сверхразрешения изображений состоит из двух чередующихся фаз обучения: обучение дискриминатора при фиксированном генераторе и обучение генератора при фиксированном дискриминаторе. Во время первой фазы обучения на вход дискриминатору попеременно подаются изображения высокого разрешения из обучающей выборки (“истинные” изображения) совместно с меткой “1” и изображения, сгенерированные генератором, совместно с меткой “0”. Целью обучения дискриминатора является стабильное различение дискриминатором сгенерированных изображений и истинных изображений. Процедура обновления параметров дискриминатора заключается в обратном распространении значений градиента функции ошибок по графу нейронной сети (“обратное распространение ошибки”). В качестве функции ошибок для дискриминатора мы использовали квадратичную функцию [23]

$$L_D = \frac{1}{2} E_X [(D(X) - 1)^2] + \frac{1}{2} E_{\tilde{x}} [(D(G(\tilde{x})))^2], \quad (8)$$

где E_X означает усреднение по набору изображений X . Параметры сети-генератора во время первой фазы зафиксированы. Во время второй фазы обучения на вход дискриминатора подаются только изображения, сгенерированные сетью-генератором, причём с противоположной по смыслу меткой “1” (“истинные” изображения). В этой фазе параметры генератора изменяются таким образом, чтобы увеличить шанс присвоения дискриминатором метки “1” сгенерированному изображению. В качестве функции ошибок для генератора также используется квадратичная функция

$$L_G = \frac{1}{2} E_{\tilde{x}} [(D(G(\tilde{x})) - 1)^2]. \quad (9)$$

Помимо этого, для того чтобы сгенерированные изображения обладали свойствами, присущими реальным изображениям, – разреженность пиксельного представления и наличие свойственных реальным изображениям паттернов – в функцию ошибок гене-

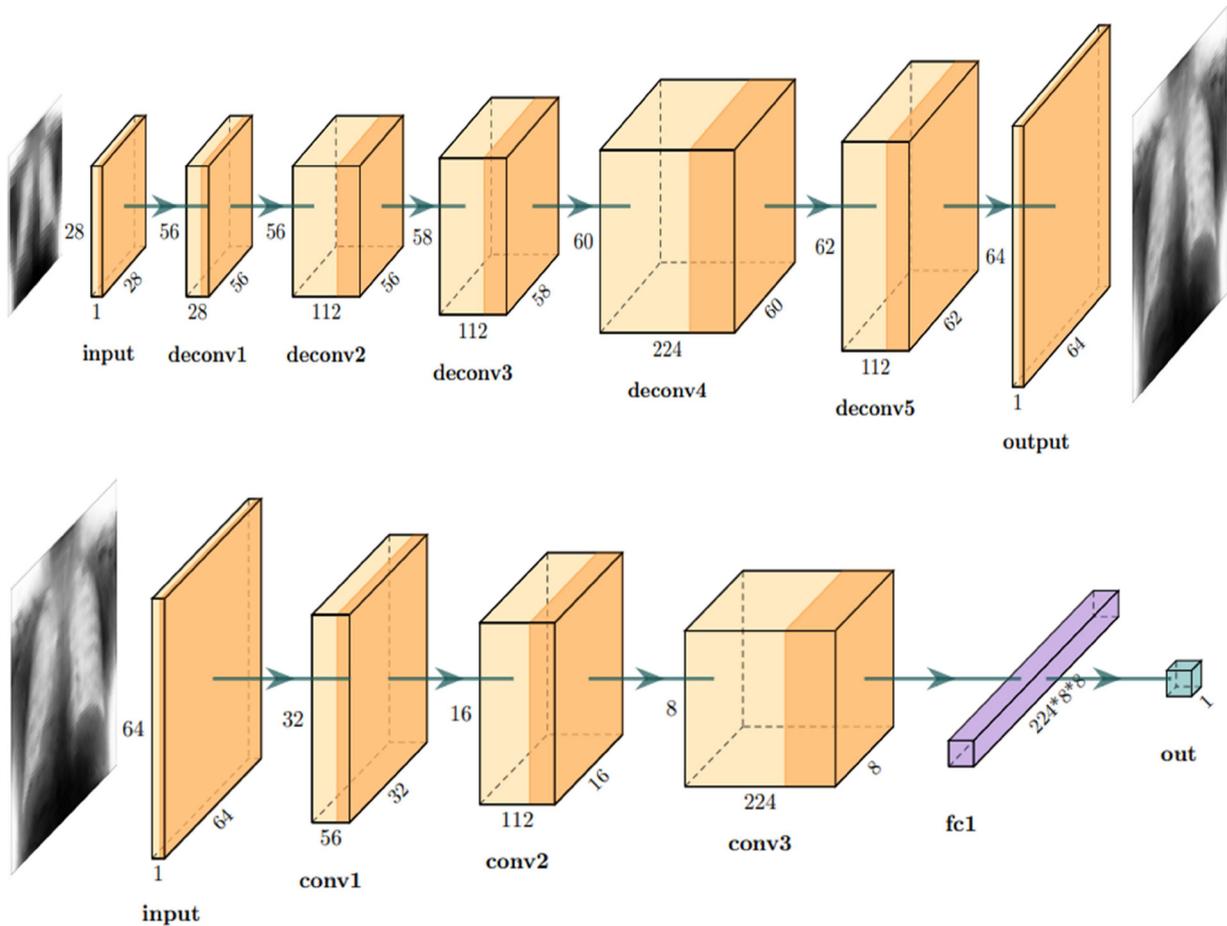


Рис. 1: Схема архитектуры нейронной сети: сеть-генератор (сверху) и сеть-дискриминатор (снизу). На вход сети-генератора подаётся изображение с низким разрешением $sN \times sN$, восстановленное из отсчётов с однопиксельной камеры. На выходе сети-генератора генерируется изображение с увеличенным разрешением $N \times N$. Сеть-дискриминатор принимает на вход изображения размера $N \times N$, полученные из обучающей выборки или сгенерированные генератором, и выдаёт на выходе вероятность того, что изображение было сгенерировано. Полученные вероятности для всех изображений обучающей выборки используются для обучения генератора конечной задаче.

ратора вводятся дополнительные слагаемые. Во-первых, вводится функция ошибки $L_{G,1}$

$$L_{G,1} = \frac{1}{WH} \sum_{i=1}^H \sum_{j=1}^W |X_{i,j} - G(\tilde{x})_{i,j}|, \quad (10)$$

где $X_{i,j}$ – компоненты истинного изображения и $G(\tilde{x})_{i,j}$ – компоненты сгенерированного изображения, W и H – ширина и высота генерируемого изображения. Функция $L_{G,1}$ оценивает попиксельное соответствие сгенерированного изображения истинному. Во-вторых, вводится функция ошибок, основанная на нейросети VGG19 [24]:

$$L_{G,VGG} = \frac{1}{W_k H_k} \sum_{i=1}^{H_k} \sum_{j=1}^{W_k} (VGG_k(X_{i,j}) - VGG_k(G(\tilde{x})_{i,j}))^2, \quad (11)$$

где VGG_k – k -й слой нейронной сети VGG19, и $VGG_k(\mathbf{x})_{i,j}$ – выход k -го слоя VGG19 для поданного на вход изображения \mathbf{x} , W_k и H_k – ширина и высота результата на выходе k -го слоя VGG19. Функция $L_{G,VGG}$ сопоставляет истинное и сгенерированное изображения в пространстве признаков предобученной нейронной сети, в котором схожесть изображений оценивается не попиксельно, а с позиции присутствия более сложных структур, присущих реальным изображениям. Таким образом, на генератор накладывается требование вносить такие структуры в генерируемые изображения.

На сегодняшний день однопиксельная визуализация в рентгеновском диапазоне уже продемонстрирована на ускорителях [25] и в системах лабораторного размера [26, 27], что делает актуальными медицинские приложения, например, однопиксельную компьютерную томографию [28]. На основании этого мы рассматриваем поднабор данных ChestMNIST из набора данных MedMNIST [29] и используем его для компьютерного моделирования нейросетевого сверхразрешения изображений в однопиксельной визуализации. Этот набор содержит пары изображений рентгенограмм грудной клетки с разрешениями 28×28 и 64×64 . Эти изображения мы рассматриваем как истинные (ground-truth) изображения, то есть сами объекты, изображения которых мы хотим получить в результате однопиксельной визуализации. Используя изображения 28×28 , мы симулируем получение отсчётов с детектора однопиксельной камеры путём перемножения каждого изображения 28×28 с набором из 64 световых паттернов, и таким образом получаем 64 значения интенсивности сигнала с детектора для каждого исходного изображения. Полученные сигналы подаются на вход генератора в свёрточной генеративной состязательной сети [22], обученной восстанавливать изображения 28×28 из 64 сигналов. В результате мы получаем восстановленные изображения 28×28 , которые

соответствуют исходным изображениям 28×28 с некоторой ошибкой. Далее, восстановленные изображения 28×28 подаются на вход следующей генеративной сети (сверхразрешающей нейросети, представленной в этой работе), увеличивающей разрешение восстановленного изображения с 28×28 до 64×64 . В итоге мы получаем восстановленные изображения высокого разрешения (64×64) и сравниваем их с исходными истинными изображениями 64×64 .

Для обучения сверхразрешающей нейросети использовалась 81231 пара изображений с разрешениями 28×28 и 64×64 , одно из которых подавалось на вход нейросети-генератору (которая генерировала изображение с разрешением 64×64), а второе подавалось на вход дискриминатору с меткой “1” (истинное). Валидационная выборка состояла из 16246 изображений и использовалась для оценки качества обучения нейросети в процессе итераций обучения (эпох) путем наблюдения за значениями функций ошибок дискриминатора (8) и генератора (9). Тестовая выборка (которую нейронная сеть не видела в процессе обучения) состояла из 1000 пар изображений и использовалась для оценки качества окончательной обученной сети-генератора. В процессе обучения для оптимизации функции ошибок использовался оптимизатор ADAM с параметром скорости обучения $lr = 0.0004$, а также $\beta_1 = 0.5$, $\beta_2 = 0.999$, процесс обучения длился 5 эпох. В качестве метрики качества восстановления изображения использовалась величина Peak Signal-to-Noise Ratio (PSNR), которая для истинного изображения высокого разрешения X и сгенерированного изображения $G(\tilde{x})$ имеет вид

$$PSNR(X, \tilde{x}) = 10 \log_{10} \frac{Max(X)}{MSE(X, \tilde{x})}, \quad (12)$$

где $Max(X)$ – максимальное значение в матрице изображения X , $MSE(X, \tilde{x})$ – среднеквадратичное отклонение между элементами матриц изображений X и \tilde{x} .

На рис. 2 представлены результаты применения генеративной состязательной сети для сверхразрешения изображения размером 28×28 , восстановленного из 64 отсчетов однопиксельной камеры при различных уровнях шума, а также соответствующее ему истинное (из набора ChestMNIST) изображение размером 64×64 . Для сравнения эффективности нашего метода мы также приводим вариант простой билинейной интерполяции восстановленного изображения. Видно, что полученное с помощью генеративной сети изображение имеет четкие детали, присутствующие на истинном изображении (чего нет на изображении, полученном с помощью билинейной интерполяции), и варьирование уровня шума в интенсивностях в практически типичных пределах (5–10% от средней интенсивности сигнала) не приводит к значительному ухудшению качества вос-

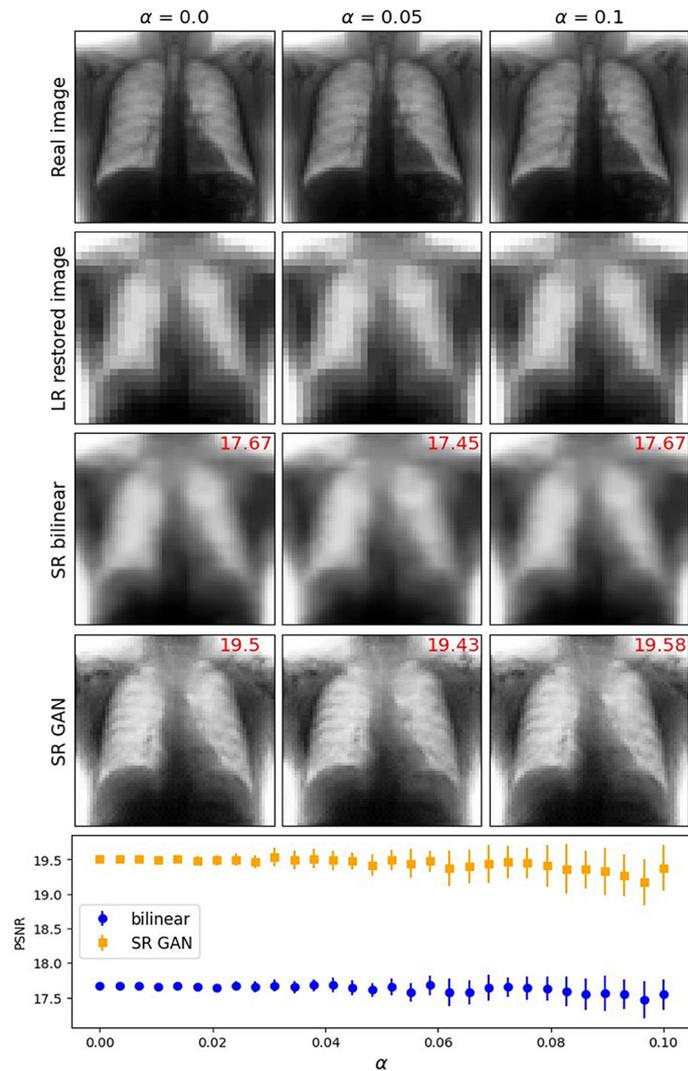


Рис. 2: Результат сверхразрешения изображения с однопиксельной камеры с использованием обученной генеративной состязательной сети. *Real image* – истинное изображение высокого разрешения. *LR restored image* – восстановленное из отсчётов однопиксельной камеры изображение с низким разрешением, *SR GAN upscaled image* – изображение с однопиксельной камеры с увеличенным посредством генеративной состязательной сети разрешением, *SR bilinear upscaled image* – изображение с однопиксельной камеры с увеличенным посредством билинейной интерполяции разрешением. В верхнем правом углу изображений с увеличенным разрешением указано значение метрики PSNR (формула (12)) между истинным изображением (1-й ряд) и изображением с увеличенным разрешением (3-й и 4-й ряды). На графике представлена зависимость метрики PSNR от уровня шума в отсчётах с однопиксельной камеры (формула (4)).

становления. При условии, что генеративная состязательная сеть обучалась на данных без симуляции шума, наши результаты демонстрируют устойчивость нейросетевого увеличения разрешения к шумам в процессе работы однопиксельной камеры. Таким образом, генеративные состязательные сети дают возможность использования однопиксельной камеры для получения изображений, обладающих чёткими деталями и заданным разрешением, при этом процесс восстановления изображений является устойчивым к шумам в процессе работы камеры.

Однако на результирующих изображениях видны отличия между сверхразрешенными изображениями и истинными изображениями. Наиболее важной причиной таких отличий является то, насколько качественно было восстановлено изображение с низким разрешением из отсчётов с однопиксельной камеры. На рис. 2 можно увидеть, что генеративная сеть качественно увеличила разрешение изображений (столбец LR restored image). В то же время можно видеть различия между восстановленными из отсчётов изображениями 28×28 и истинными изображениями 28×28 из набора данных ChestMNIST. Такие различия возникают из-за оптимизационного характера обучения нейронных сетей: в процессе обучения мы приходим в один из локальных минимумов многомерной функции ошибок, при котором нейронная сеть восстанавливает изображения из обучающего набора “достаточно хорошо” по выбранной целевой метрике (см. формулы (9), (10), (11)). В то же время ни одно из изображений обучающего набора не восстанавливается идеально, то есть не даёт нулевого значения целевой метрики. Для изображений вне обучающего набора правильно обученная нейронная сеть будет восстанавливать изображения с качеством, сравнимым с качеством на обучающем наборе, и восстановленные изображения так же будут содержать погрешности. Если затем использовать восстановленные изображения для сверхразрешения, то получим изображения, содержащие отличия от истинных изображений (изображений 64×64 из набора данных ChestMNIST). Таким образом, качество восстановления изображений с низким разрешением из отсчётов является значимым фактором успешного получения изображений с высоким разрешением.

Заключение. В данной работе мы продемонстрировали применение генеративных состязательных сетей для сверхразрешения изображений, полученных из численной компьютерной симуляции обработки последовательности измерений однопиксельной камеры. Мы использовали генеративно-состязательную сеть с функцией ошибок наименьших квадратов для увеличения разрешения изображений с первоначального разрешения 28×28 до увеличенного разрешения 64×64 . Для того чтобы нейронная сеть

обучалась генерации реалистичных изображений, в качестве дополнительных слагаемых в функции ошибки сети-генератора мы использовали $L_{G,1}$ ошибку, оценивающую попиксельное соответствие восстановленного изображения целевому изображению, и $L_{G,VGG}$ ошибку, оценивающую реалистичность изображения с точки зрения предобученной сверточной сети VGG19. В результате мы показали, что обученная генеративная сеть способна увеличивать разрешение изображений с однопиксельной камеры без размытия, свойственного интерполяционным методам.

На основе проведенной работы выделим несколько актуальных направлений дальнейших исследований. Во-первых, для решения задачи сверхразрешения изображений, сгенерированных однопиксельной камерой, могут подойти различные генеративные модели нейронных сетей. Поиск модели, оптимизированной под особенности работы однопиксельной камеры, представляет собой важную практическую задачу. В частности, в такой модели может быть реализован учет реалистичных шумов однопиксельного детектора и, в более широком смысле, особенности алгоритма получения первичного изображения. Во-вторых, отметим проблему обучения нейронных сетей. Однопиксельные камеры изначально предназначены для использования в приложениях, где применение традиционных многопиксельных камер затруднительно. Однако множество реальных изображений, которые можно использовать для обучения нейронных сетей, получено именно от многопиксельных камер, работающих в видимом диапазоне. Такие изображения могут быть далеки от объектов-целей применения однопиксельных камер, и поэтому обучение нейронных сетей на таких изображениях не гарантирует успешность применения обученных нейронных сетей в однопиксельных камерах. Поэтому исследование возможностей и ограничений в применении изображений из видимого диапазона для обучения нейронных сетей в задачах однопиксельной визуализации представляется еще одной интересной задачей.

Исследование выполнено за счет гранта Российского научного фонда № 23-22-00381, <https://rscf.ru/project/23-22-00381/>.

Л И Т Е Р А Т У Р А

- [1] L. Bian, J. Suo, G. Situ, et al., Scientific Reports **6** (2016). <https://doi.org/10.1038/srep24752>.
- [2] Z. Zhang, S. Liu, J. Peng, et al., Optica **5**, 315 (2018). <https://doi.org/10.1364/OPTICA.5.000315>.

- [3] Y. Zhang, M. P. Edgar, B. Sun, et al., *Journal of Optics* **18**, 035203 (2016). <https://doi.org/10.1088/2040-8978/18/3/035203>.
- [4] J. Greenberg, K. Krishnamurthy, D. Brady, *Optics Letters* **39**, 111 (2013). <https://doi.org/10.1364/OL.39.000111>.
- [5] M. P. Olbinado, D. M. Paganin, Y. Cheng, A. Rack, *Optica* **8**(12), 1538 (2021). <https://doi.org/10.1364/OPTICA.437481>.
- [6] M. Shcherbatenko, M. Elezov, N. Manova, et al., *Appl. Phys. Lett.* **118**, 181103 (2021). <https://doi.org/10.1063/5.0046049>.
- [7] M. J. E. Golay, *J. Opt. Soc. Am.* **39**, 437 (1949). <https://doi.org/10.1364/JOSA.39.000437>.
- [8] J. A. Decker, M. O. Harwitt, *Appl. Opt.* **7**, 2205 (1968). <https://doi.org/10.1364/AO.7.002205>.
- [9] M. F. Duarte, M. A. Davenport, D. Takhar, et al., *IEEE Signal Processing Magazine* **25**, 83 (2008). <https://doi.org/10.1109/MSP.2007.914730>.
- [10] M. D. Aksenov, D. V. Sych, *Journal of Russian Laser Research* **39**, 492 (2018). <https://doi.org/10.1007/s10946-018-9744-y>.
- [11] D. Sych, M. Aksenov, *AIP Conference Proceedings* **1936**, 020016 (2018). <https://doi.org/10.1063/1.5025454>.
- [12] E. J. Candès, J. K. Romberg, T. Tao, *Comm. Pure Appl. Math.* **59**, 1207 (2006). <https://doi.org/10.1002/cpa.20124>.
- [13] D. Donoho, *IEEE Trans. Inform. Theory* **52**, 1289 (2006). <https://doi.org/10.1109/TIT.2006.871582>.
- [14] M. Lyu, W. Wang, H. Wang, et al., *Scientific Reports* **7** (2017). <https://doi.org/10.1038/s41598-017-18171-7>.
- [15] Y. He, G. Wang, G. Dong, et al., *Scientific Reports* **8** (2018). <https://doi.org/10.1038/s41598-018-24731-2>.
- [16] T. Shimobaba, Y. Endo, T. Nishitsuji, et al., *Optics Communications* **413**, 147 (2018). <https://doi.org/10.1016/j.optcom.2017.12.041>.
- [17] D. Sych, *Scientific Visualization* (2024) [in press].
- [18] A. Osicheva, D. Sych, *Sensors* **24**, 4689 (2024). <https://doi.org/10.3390/s24144689>.
- [19] B. Moser, F. Raue, S. Frolov, et al., *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 9862-9882 (2023). <http://dx.doi.org/10.1109/TPAMI.2023.3243794>.
- [20] Д. В. Сыч, *Краткие сообщения по физике ФИАН* **51**(6), 27 (2024). <https://doi.org/10.3103/S1068335624600463>.
- [21] D. Sych, *Journal of Russian Laser Research* **45**, 286 (2024). <https://doi.org/10.1007/s10946-024-10213-6>.
- [22] Д. В. Бабухин, А. А. Реутов, Д. В. Сыч, *Компьютерная оптика* [принято к печати].
- [23] X. Mao et al., *IEEE International Conference on Computer Vision (ICCV)*, Venice,

- Italy, pp. 2813-2821 (2017). <https://doi.org/10.1109/ICCV.2017.304>.
- [24] C. Ledig et al., IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, pp. 105-114 (2017). <https://doi.org/10.1109/CVPR.2017.19>.
- [25] D. Pelliccia, A. Rack, M. Scheel, et al., Phys. Rev. Lett. **117**, 113902 (2016). <https://doi.org/10.1103/PhysRevLett.117.113902>.
- [26] A.-X. Zhang, Y.-H. He, L.-A. Wu, et al., Optica **5**, 374 (2018). <https://doi.org/10.1364/OPTICA.5.000374>.
- [27] Y.-H. He, A.-X. Zhang, M.-F. Li, et al., APL Photonics **5**, 056102 (2020). <https://doi.org/10.1063/1.5140322>.
- [28] A. Ben-Yehuda, O. Sefi, Y. Klein, et al., Commun. Eng. **3**, 39 (2024). <https://doi.org/10.1038/s44172-024-00184-6>.
- [29] J. Yang, R. Shi, D. Wei, et al., “MedMNIST v2-A large-scale lightweight benchmark for 2D and 3D biomedical image classification.” Scientific Data, 2023.

Поступила в редакцию 16 сентября 2024 г.

После доработки 22 ноября 2024 г.

Принята к публикации 26 ноября 2024 г.