



DOI: <https://doi.org/10.30898/1684-1719.2025.11.39>

УДК: 621.396

ОЦЕНКИ ЭФФЕКТИВНОСТИ МЕТОДОВ РЕКОНСТРУКЦИИ ИСКАЖЕННЫХ ИЗОБРАЖЕНИЙ ПРИ РАЗЛИЧНЫХ УРОВНЯХ ДИСКРЕТИЗАЦИИ

А.В. Кокошкин

ИРЭ им. В.А. Котельникова РАН, Фрязинский филиал,
141190, Фрязино, пл. Введенского, 1

Статья поступила в редакцию 19 сентября 2025 г.

Аннотация. Предложена оценка эффективности методов реконструкции, созданная на основе адаптации известной метрики «средняя абсолютная процентная ошибка» адаптированной к задачам обработки цифровых изображений. Показана качественная схожесть оценок по метрикам «адаптивная средняя абсолютная процентная ошибка» и «мера структурного подобия», а их количественные расхождения позволяют говорить об их взаимодополняемости. Результаты сравнительного анализа указывают на высокое качество работы использованных методов восстановления: адаптивный метод опорного изображения (АМОИ), метод перенормировки с ограничением, модификация фильтра Винера на основе АМОИ.

Ключевые слова: обработка изображений, метрики оценок качества, уровни дискретизации, методы реконструкции изображений.

Финансирование: Работа выполнена в рамках государственного задания ИРЭ им. В.А. Котельникова РАН.

Автор для переписки: Кокошкин Александр Владимирович, shvarts65@mail.ru

Введение

Искажение изображений и шумы – неизбежная проблема, возникающая в различных областях, от дистанционного зондирования Земли и астрономии, до медицинской визуализации и видеонаблюдения. Причины искажений могут быть разнообразными: шум, помехи, размытие, геометрические деформации, потеря информации и другие артефакты. Реконструкция (восстановление) искаженных изображений – это процесс восстановления оригинального, неискаженного изображения на основе имеющихся данных. Существует большое количество методов восстановления искаженных изображений, каждый из которых предназначен для решения конкретных задач. Вот некоторые из них:

Инверсная (Обратная) фильтрация – простой, но часто неустойчивый метод, чувствительный к шуму. Метод регуляризации А.Н. Тихонова применяется для обработки изображений в задачах, требующих устойчивого решения некорректных задач. (метод минимизации сглаживающего функционала со связью). Фильтр Винера учитывает статистику шума и сигнала для более устойчивой реконструкции [1 – 4].

Итеративные методы (например, метод Ландвебера) – постепенно улучшают изображение, минимизируя ошибку между реконструированным и искаженным изображением [5].

Методы на основе глубокого обучения (например, сверточные нейронные сети): обучаются на больших наборах данных для эффективного удаления размытия [6].

Адаптивный метод опорного изображения (АМОИ), Метод перенормировки с ограничением, Модификация фильтра Винера на основе АМОИ разработаны для решения задач восстановления изображений, искаженных известной аппаратной функцией (АФ), при наличии неизвестных помех и шума [7 – 9].

Оценки эффективности методов реконструкции зависят от типа искажения и задачи. Поэтому важно использовать как объективные, так и

субъективные метрики. Наиболее часто используемые объективные метрики (основаны на сравнении реконструированного изображения с оригинальным) [1, 10]:

MSE (Mean Squared Error – среднеквадратическая ошибка): среднее значение квадратов разностей между соответствующими пикселями реконструированного и оригинального изображений. Более низкое значение MSE указывает на лучшее качество.

PSNR (Peak Signal-to-Noise Ratio – отношение пикового сигнала к шуму): измеряет отношение максимальной возможной мощности сигнала к мощности искажающего шума. Более высокое значение PSNR указывает на лучшее качество реконструкции.

SSIM (Structural Similarity Index Measure – мера структурного подобия): оценивает сходство между двумя изображениями, учитывая яркость, контрастность и структуру. Лучше коррелирует с человеческим восприятием качества изображения, чем PSNR.

MAPE (Mean Absolute Percentage Error, MAPE) – средняя абсолютная процентная ошибка, выражает среднее абсолютное отклонение прогнозируемых значений от фактических значений в процентах.

Кроме того, при проведении исследований, зачастую могут использоваться другие объективные метрики [10 – 13]: оценка резкости, средний контраст, средняя яркость, эксцесс, асимметрия, мера спектрального подобия, СКО разности фазы (с эталонным спектром), мера гистограммного подобия.

Субъективные метрики основаны на оценке качества реконструированных изображений людьми:

MOS (Mean Opinion Score – средняя оценка мнения): группа экспертов или обычных пользователей оценивает качество изображений по шкале (например, от 1 до 5). Среднее значение оценок является MOS.

ABR (Absolute Category Rating – абсолютная рейтинговая категория): аналогично MOS, но пользователи оценивают изображения по категориям (например, “отличное”, “хорошее”, “удовлетворительное”, “плохое”).

Подходы к оценке эффективности:

1) Сравнение с эталонным изображением (Ground Truth): наиболее точный подход, когда доступно оригинальное, неискаженное изображение. Объективные метрики (PSNR, SSIM, MSE и др.) используются для количественной оценки близости реконструированного изображения к эталону.

2) Оценка на основе задачи (Task-Based Evaluation): эффективность метода оценивается по тому, насколько хорошо реконструированное изображение позволяет выполнить определенную задачу. Например:

- В медицинской диагностике: насколько точно врач может поставить диагноз по реконструированному изображению.

- В распознавании объектов: насколько хорошо алгоритм распознавания объектов работает с реконструированными изображениями.

- В анализе текстур: насколько хорошо реконструированное изображение передает характерные текстурные особенности.

Эффективность нового метода необходимо сравнить с существующими передовыми методами на стандартных наборах данных. Это позволяет понять, насколько новый метод конкурентоспособен.

В качестве искажения выбрана Аппаратная функция дефокусировки. Исследуется влияние шума дискретизации на реконструкцию искаженного изображения. Какие-либо другие шумы (мультипликативные, аддитивные) или помехи при моделировании исключаются. Тестируемые методы: метод перенормировки с ограничением (МПО), Адаптивный метод опорного изображения (АМОИ), Фильтр Винера (ФВ), Модификация фильтра Винера на основе АМОИ (МФВ).

В этой работе предложена оценка эффективности методов реконструкции, созданная на основе адаптации известной метрики «Средняя абсолютная процентная ошибка» (MAPE) адаптированной к задачам обработки

цифровых изображений. Поскольку MAPE метрика, которая выражает среднее абсолютное отклонение прогнозируемых значений от фактических значений в процентах, она удобна для интерпретации результатов. MAPE менее чувствительна к большим ошибкам по сравнению со средней квадратичной ошибкой (MSE), что делает ее полезной в задачах, где важна стабильность предсказаний. В нашей работе, кроме адаптации MAPE для задач обработки цифровых изображений (о чем будет сказано ниже) предлагается вычислять метрику «Адаптивная средняя абсолютная процентная ошибка» (Adaptive Mean Absolute Percentage Error, AMAPE):

$$\text{AMAPE} = 100 - \text{MAPE}.$$

Это делает оценку более наглядной. Если AMAPE равна 100, значит два изображения абсолютно одинаковы. Чем ниже значение AMAPE (вплоть до нуля), тем два сравниваемых изображения больше не похожи друг на друга.

Сравнение предложенной метрики AMAPE в предложенной работе проводится с SSIM, которая на сегодня является наиболее универсальной. Отношение пикового сигнала к шуму (PSNR) показали результаты сходные с AMAPE и SSIM, но ввиду меньшей наглядности в этой статье не приводятся.

1. Адаптивная средняя абсолютная процентная ошибка

Уровни дискретизации определяют количество возможных значений, которые может принимать цифровой сигнал. Обычно они выражаются в битах. Например, 8-битное изображение имеет $2^8 = 256$ уровней дискретизации, а 16-битное изображение — $2^{16} = 65536$ уровней. Чем больше уровней дискретизации, тем точнее цифровой сигнал представляет исходный аналоговый сигнал.

Рис. 1а. демонстрирует исходное неискаженное изображение 256 уровней дискретизации размером 256 на 256 пикселей. Рис. 1б. показывает изображение рис. 1а в объеме, «вид сбоку». Все точки рис. 1б. черные, но по вертикальной оси о рис. 1б. отложены градации яркостей ($I(i, j)$), которые должны быть у этих точек изображения (как на рис. 1а), от нуля (черный цвет), до 255 (белый цвет).

По горизонтальной оси рис. 1б. показаны индексы (i) пикселей по одной из осей плоскости изображения.




Рис. 1. Исходное неискаженное изображение 256 уровней дискретизации, размером 256 на 256 пикселей – а). Изображение рис. 1а в объеме – б).




Рис. 2. Исходное изображение рис. 1а искаженное аппаратной функцией «круглое пятно» радиусом $S_0 = 6$ размером, машинная точность – а). Изображение рис. 2а в объеме – б).

Рис. 2а. демонстрирует исходное изображение рис. 1а искаженное аппаратной функцией «круглое пятно» радиусом $S_0 = 6$, дискретизации с

машинной точностью, нормированное по градациям яркостей от нуля (черный цвет), до 255 (белый цвет). Рис. 2б. показывает изображение рис. 2а в объеме, «вид сбоку» аналогично рисунку рис. 1б.

Рис. 3а. демонстрирует изображение, искаженное рис. 2а с 16 уровнями дискретизации (яркости) нормированное по градациям яркостей от нуля (черный цвет), до 255 (белый цвет). Рис. 3б. показывает изображение рис. 3а в объеме, «вид сбоку» аналогично рисунку рис. 3б. На рис. 3б хорошо видно, что точки изображения присутствуют только на 16 уровнях яркостей. При внимательном изучении рис. 3а можно различить эти уровни яркостей.




Рис. 3. Исходное изображение рис. 1а искаженное аппаратной функцией «круглое пятно» радиусом $S_0 = 6$ размером, 16 уровней дискретизации – а). Изображение рис. 3а в объеме – б).

Подобную операцию проводим для каждого варианта уровней дискретизации меньше 256. После этого проводим, разными способами, реконструкцию искаженных изображений. Затем, оцениваем их качество по объективным критериям и сравниваем полученные результаты между используемыми методами. Адаптация предложенной метрики производится таким образом, чтобы в конечном итоге можно было сравнивать качество реконструированных изображений от машинной точности и 16-и битных с 4-х битными. Приводим результаты к размерности 8-и битных цифровых

изображений. Проведем численный эксперимент для пояснения функционирования предложенной здесь метрики «Адаптивная средняя абсолютная процентная ошибка» (Adaptive Mean Absolute Percentage Error, AMAPE). Рис. 4.а показывает случайно – равномерным образом сгенерированное изображение размером 256 на 256 пикселей.




Рис. 4. Модель изображений: условное «идеальное» изображение с постоянной яркостью 127 (Mean) и случайно-равномерные черные точки (Random) «вид сверху» – а); рис. 4а в объеме – б).

Рис. 4б. показывает изображение рис. 4а в объеме. Серая плоскость посередине рис. 4б это условное «идеальное» изображение с постоянной яркостью 127 (среднее число между нулем и 255). Случайно-равномерно набросанные точки на рис. 4 условно полагаем тестируемым изображением. Все случайные точки на рис. 4. для наглядности черные, но по вертикальной оси $I(i, j)$ рис. 4б отложены градации яркостей, которые должны быть у этих точек изображения, от нуля (черный цвет), до 255 (белый цвет).

Вычислим «Абсолютную ошибку» (Absolute Error, AE) между «идеальным» (Mean) (127) и тестируемым (Random) изображениями рис. 4 ($N_1 = 256$ и $N_2 = 256$ размер изображения в пикселях):

$$AE = \sum_{i_1=0}^{N_1-1} \sum_{i_2=0}^{N_2-1} (|127 - Random_{i_1, i_2}|)$$

Средняя абсолютная ошибка (Mean Absolute Error, MAE) $N1 = 256$ и $N2 = 256$:

$$MAE = \frac{AE}{N1 \cdot N2} = 63,858$$

Адаптивная средняя абсолютная процентная ошибка (Adaptive Mean Absolute Percentage Error, AMAPE):

$$AMAPE = 100 - \left(\frac{MAE \cdot 100}{64} \right) = 0,222$$

Таким образом, получаем оценку сходства менее одного процента. Т.е. тестируемое изображение совсем не похоже на «идеальное». В последней формуле деление происходит на 64 что соответствует половине от средней яркости. Поскольку генератор случайных чисел равномерно разбросал точки по всему полю изображения и Средняя абсолютная ошибка (MAE) должна в идеале стремиться к 64.

Теперь, в нашем численном эксперименте, в качестве «идеального» используем исходное неискаженное изображение рис. 1а. Рис. 5, аналогичен рис. 4, но «идеальное» изображение с постоянной яркостью 127 заменено на исходное неискаженное изображение рис. 1а.

Вычислим «Абсолютную ошибку» (Absolute Error, AE) между «идеальным» (*Original*) и тестируемым изображениями рис. 5 ($N1 = 256$ и $N2 = 256$ размер изображения в пикселях):

$$AE = \sum_{i1=0}^{N1-1} \sum_{i2=0}^{N2-1} (|Original_{i1,i2} - Random_{i1,i2}|)$$

$$MAE = \frac{AE}{N1 \cdot N2} = 80,17$$

При превышении MAE уровня 64 для 8-битных изображений замена ($MAE = 80,17$) на $MAE = 64$. Иначе получится отрицательное значение.

$$AMAPE = 100 - \left(\frac{MAE \cdot 100}{64} \right) = 0$$




Рис. 5. «Идеальное» (*Original*) исходное неискаженное изображение рис. 1а и случайно-равномерные черные точки (*Random*) «вид сверху» – а); рис. 5а в объеме – б).

Проведенный численный эксперимент подтверждает предположение о справедливости предложенной адаптации метрики «средняя абсолютная процентная ошибка» к сравнению между собой 8-и битных изображений (имеющих 256 уровней дискретизации).

Для сравнения реконструированных (*Reconstruction*) изображений с «идеальным» (*Original*) вычисляем адаптивную среднюю абсолютную процентную ошибку по формулам:

$$AE = \sum_{i1=0}^{N1-1} \sum_{i2=0}^{N2-1} (|Original_{i1,i2} - Reconstruction_{i1,i2}|)$$

$$MAE = \frac{AE}{N1 \cdot N2}$$

При превышении MAE уровня 64 для 8-битных изображений замена на $MAE = 64$. Иначе получится отрицательное значение.

Таким образом, получаем окончательно:

$$AMAPE = 100 - \left(\frac{MAE \cdot 100}{64} \right)$$

2. Сравнение метрик AMAPE и SSIM на примере реконструкции искаженных изображений разными методами

В предложенной работе исследуется влияние количества уровней дискретизации исходного искаженного изображения на результат реконструкции. Т.е. исходное искаженное изображение моделируется в пяти вариантах:

- 1) Машинная точность (численный процессор Mathcad работает с числами, имеющими 17 десятичных разрядов).
- 2) 16-битное изображение – $2^{16} = 65536$ уровней дискретизации (яркости).
- 3) 8-битное изображение – $2^8 = 256$ уровней дискретизации (яркости).
- 4) 6-битное изображение – $2^6 = 64$ уровней дискретизации (яркости).
- 5) 4-битное изображение – $2^4 = 16$ уровней дискретизации (яркости).

Результаты по дальнейшему снижению уровней дискретизации здесь не приводятся поскольку это приводит к неустойчивым результатам по распознаванию восстановленных изображений. Каким бы ни было количество уровней дискретизации исходных данных, восстановление производится по 8-и битному стандарту (256 уровней дискретизации), который имеет самое широкое распространение. Таким образом, исследуется влияние количества уровней дискретизации исходных данных с разной дискретизацией на информативность изображений, получаемых при реконструкции.

На рис. 6а и рис. 6б изображены, в логарифмическом масштабе, амплитудные пространственные спектры изображений, соответственно – для исходного неискаженного (рис. 1а) и искаженного аппаратной функцией «круглое пятно» радиусом $S_0 = 6$ (рис. 2а).

Необходимо сказать, что здесь и далее по тексту статьи, рисунки амплитудных спектров центрированы, т.е. нулевая гармоника (средняя яркость) находится в центре изображения [1]. Спектр на рис. 6б вычислен для дискретизации «машинная точность». Обратим внимание, что спектр для дискретизации «машинная точность» внешне (в публикуемом здесь масштабе рисунка) практически не отличается от спектра для 16-битного изображения

(65536 уровней дискретизации). На рис. 6в и рис. 6г показаны, в логарифмическом масштабе, трансформации амплитудных пространственных спектров искаженного изображения рис. 2а при разных уровнях дискретизации, переведенные в 8-битный формат.

Спектр на рис. 6в соответствует 8-битному изображению (256 градаций яркости). Визуально (для человеческого восприятия) 8-битное изображение неотлично от этого же изображения с более высокой дискретизацией. Поэтому нет смысла приводить здесь рисунок для него. То же самое можно сказать об экспертной оценке вплоть до 64 градаций яркостей. Человек при наблюдении не обнаружит практической разницы в качестве восприятия изображений с «идеалом» машинной точности. Но при дальнейшем уменьшении количества уровней дискретизации изменения становятся все более заметны наблюдателю (эксперту).




Рис. 6. Амплитудные пространственные спектры, в логарифмическом масштабе, для изображений: рис. 1а – а); рис. 2а дискретизация «машинная точность» – б); 256 уровней дискретизации – в); рис. 3а (16 уровней дискретизации) – г).

На рис. 7 демонстрируется исходное идеальное изображение (без дефокусировки) с 16 уровнями дискретизации.




Рис. 7. Исходное изображение без дефокусировки, 16 уровней дискретизации, размером – а). Амплитудный пространственный спектр, в логарифмическом масштабе, для изображения рис. 7а – б).

При внимательном рассмотрении видны уровни постоянных яркостей (в виде ореолов). Амплитудный пространственный спектр этого изображения (рис. 7б) внешне мало отличается от спектра рис. 6а (спектр исходного изображения с машинной точностью). Дело в том, что шум квантования, хотя и увеличивается с уменьшением количества градаций яркостей, но к 16 уровням дискретизации еще не превышает величины гармоник значимых для распознавания объектов на изображении. Это видно при сравнении рис. 6г и рис. 7б.

На рис. 6г показан спектр для 4-битного изображения рис. 3а (16 уровней дискретизации). Рис. 6а, рис. 7а и рис. 7б последовательно демонстрируют негативные изменения спектра искаженного дефокусировкой изображения вызванные уменьшением количества уровней дискретизации. Таким образом, показано, что в качестве «шума» в нашем исследовании выступает шум дискретизации (шум квантования).

Реконструкция искажения аппаратной функцией «круглое пятно» радиусом $S_0 = 6$, при отсутствии других шумов и помех и при дискретизации «машинная точность» не вызывает никаких затруднений у используемых для восстановления методов. То же самое можно сказать и о дискретизации на 65536 уровней яркости. Далее показаны результаты реконструкции для самого тяжелого из рассматриваемых случаев. Рис. 8 демонстрирует восстановление искаженного изображения при 16 уровнях дискретизации (рис. 3а). Соответственно: МПО – а), АМОИ – б), ФВ – в), МФВ – г). При восстановлении с помощью фильтра Винера, для каждого из уровней дискретизации, вручную подбирался соответствующий коэффициент (соответствующий отношению сигнал/шум) для наилучшего результата реконструкции по объективным критериям (метрикам AMAPE и SSIM). Эти коэффициенты использовались и при реконструкции с помощью модифицированного фильтра Винера. Метод перенормировки с ограничением и адаптивный метод опорного изображения не нуждаются в подобной подгонке.



Рис. 8 Реконструкции рис. 3а с помощью МПО – а), АМОИ – б), ФВ – в), МФВ – г).

В качестве начального приближения (точки отсчета) вычислим метрики AMAPE и SSIM для разницы между исходным идеальным изображением (рис. 1а) и идеальным изображением, искаженным только дискретизацией (рис. 7а при 16 уровнях дискретизации). На рис. 9а, в виде графиков, для разных методов реконструкции, представлена вычисленная адаптивная средняя абсолютная процентная ошибка AMAPE. Обозначения на графике означают:

По вертикальной оси:

- ECRM – ошибка восстановления МПО (Error Constrained Renormalization Method)
- EARIM – ошибка восстановления АМОИ (Error Adaptive Reference Image Method)
- EWF – ошибка восстановления ФВ (Error Wiener Filter)
- EMWF – ошибка восстановления МФВ (Error Modified Wiener Filter)
- EORIG – ошибка для идеального изображения искаженного только дискретизацией (Error Original image).

По горизонтальной оси число уровней дискретизации:

- $d_i = 0$ – «машинная точность»
- $d_i = 1$ – 65536 уровней дискретизации
- $d_i = 2$ – 256 уровней дискретизации
- $d_i = 3$ – 64 уровней дискретизации
- $d_i = 4$ – 16 уровней дискретизации




Рис. 9 Для тестового изображения «портрет», в зависимости от числа уровней дискретизации d_i . Адаптивная средняя абсолютная процентная ошибка – а). Мера структурного подобия – б).

На рис. 9б, в виде графиков, для разных методов реконструкции, представлена мера структурного подобия SSIM. Обозначения на графике означают:

По вертикальной оси:

- SCRM – SSIM восстановления МПО (SSIM Constrained Renormalization Method)
- SARIM – SSIM восстановления АМОИ (SSIM Adaptive Reference Image Method)
- SWF – SSIM восстановления ФВ (SSIM Wiener Filter)
- SMWF – SSIM восстановления МФВ (SSIM Modified Wiener Filter)
- SORIG – SSIM для идеального изображения искаженного только дискретизацией (SSIM Original image).

По горизонтальной оси обозначения аналогичны рис. 9а.

Оценки качества реконструированных изображений анализируют их «похожесть» на «идеальное» исходное не искаженное изображение. Из сравнительного анализа рис. 1а, рис. 7 и изучения рис. 9 можно сделать заключение о том, что метрика AMAPE более чувствительна к искажениям (артефактам) на восстановленных изображениях, чем SSIM.

Для обеих метрик идеальное изображение, искаженное только дискретизацией (EORIG, SORIG – голубой цвет на графиках) имеет самые лучшие показатели по сравнению с реконструкциями из дефокусированных образцов. Это является пределом того, к чему должно стремиться каждое восстановление разными методами. Не смотря на явно видимые ореолы на реконструированных образцах, мера структурного подобия показывает высокое соответствие оригиналу. Даже при 16 уровнях дискретизации SSIM для всех методов реконструкции выше 0,9. Это означает более чем 90 процентное соответствие для идентификации изображений. Что касается адаптивной средней абсолютной процентной ошибки, то ее значения изначально (для «машинной точности») выше 90 процентов (за исключением МПО – немного

более 80 процентов). С уменьшением количества уровней дискретизации AMAPE снижается до уровня чуть больше 60 – 75 процентов.

Из анализа рис. 8 можно сделать заключение о том, что в отсутствии дополнительных шумов и помех классический фильтр Винера (EWF, SWF) хорошо справляется с поставленной задачей особенно при большом количестве уровней дискретизации. А модифицированный ФВ (EMWF, SMWF) лидирует по всем показателям даже при малом количестве градаций яркости. Отдельно стоит отметить метод перенормировки с ограничением. Он, не смотря на относительно не такие высокие показатели метрик, при больших количествах уровней дискретизации, показывает самую лучшую стабильность на всем диапазоне изменений градаций яркостей (ECRM, SCRM).

Для дополнительного анализа был использован Онлайн-сервис визуальной аналитики от компании «Яндекс» для распознавания текста и объектов на изображениях с помощью программных моделей машинного обучения. Объект на изображении (портрет девушки) был опознан системой для всех методов реконструкции.

Все вышесказанное указывает на достаточно высокое качество работы методов восстановления. Качественная схожесть оценок по метрикам AMAPE и SSIM, но их количественные расхождения позволяют говорить об их взаимодополняемости.

Заключение

В этой работе предложена оценка эффективности методов реконструкции, созданная на основе адаптации известной метрики «Средняя абсолютная процентная ошибка» (MAPE) адаптированной к задачам обработки цифровых изображений. Поскольку MAPE метрика, которая выражает среднее абсолютное отклонение прогнозируемых значений от фактических значений в процентах, она удобна для интерпретации результатов. Показана качественная схожесть оценок по метрикам «адаптивная средняя абсолютная процентная ошибка» (Adaptive Mean Absolute Percentage Error, AMAPE) и «мера

структурного подобия» (Structural Similarity Index Measure, SSIM), а их количественные расхождения позволяют говорить об их взаимодополняемости.

Результаты сравнительного анализа указывают на достаточно высокое качество работы использованных методов восстановления (адаптивный метод опорного изображения, метод перенормировки с ограничением, модификация фильтра Винера на основе АМОИ). По результатам исследования можно констатировать, что модифицированный фильтр Винера лидирует по всем показателям особенно при малом количестве градаций яркости. Отдельно стоит отметить метод перенормировки с ограничением. Он, не смотря на относительно не такие высокие показатели метрик при больших количествах уровней дискретизации, показывает самую лучшую стабильность на всем диапазоне изменений градаций яркостей.

Финансирование: Работа выполнена в рамках государственного задания ИРЭ им. В.А. Котельникова РАН.

Литература

1. Gonzalez R.C., Woods R.E., Digital Image Processing. NJ.: Prentice Hall, International Version 3rd Edition. – 2012. – 1071 p.
2. Бейтс Р., Мак-Доннелл М. Восстановление и реконструкция изображений: Пер. с англ. – Мир – 1989. – 288 с.
3. Прэтт У. Цифровая обработка изображений: В 2-х кн. – 1982. – 738 с.
4. Грузман И.С. и др. Цифровая обработка изображений в информационных системах // Новосибирск: НГТУ. – 2002. – С. 352.
5. Hanke M., Neubauer A., Scherzer O. A convergence analysis of the Landweber iteration for nonlinear ill-posed problems // Numerische Mathematik. – 1995. – V. 72. – №. 1. – P. 21-37. <https://doi.org/10.1007/s002110050158>
6. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. – 2015. – V. 521. – №. 7553. – P. 436-444. <https://doi.org/10.1038/nature14539>

7. Гуляев Ю.В. и др. Коррекция пространственного спектра, искаженного оптической системой, с помощью метода опорного изображения. Часть 1-3. // Журнал радиоэлектроники. – 2013. – №. 12.
8. Кокошкин А.В. и др. Использование метода перенормировки с ограничением для восстановления искаженных изображений при наличии помех и шума с неизвестными параметрами // Журнал радиоэлектроники. – 2015. – №. 7.
9. Кокошкин А.В., Новичихин Е.П. Модификация фильтра Винера на основе метода опорного изображения. // Журнал радиоэлектроники. 2024. – №. 11. <https://doi.org/10.30898/1684-1719.2024.11.10>
10. Кокошкин А.В. и др. Сравнение объективных методов оценки качества цифровых изображений // Журнал радиоэлектроники. – 2015. – №. 6.
11. Кокошкин А.В. Оценка спектрального подобия цифровых изображений // Журнал радиоэлектроники. – 2020. – №. 8. – С. 14-14. <https://doi.org/10.30898/1684-1719.2020.8.4>
12. Кокошкин А.В. Методы интерполяции разреженных изображений, работающие в частотной области // Журнал радиоэлектроники. – 2023. – №. 3. <https://doi.org/10.30898/1684-1719.2023.3.10>
13. Кокошкин А.В., Новичихин Е.П. Оценка качества изображений, полученных дистанционным зондированием // РЭНСИТ: Радиоэлектроника. Наносистемы. Информационные технологии. – 2023. – Т. 15. – №. 3. – С. 327-334. <https://doi.org/10.17725/rensit.2023.15.327>

Для цитирования:

Кокошкин А.В. Оценки эффективности методов реконструкции искаженных изображений при различных уровнях дискретизации // Журнал радиоэлектроники. – 2025. – №. 11. <https://doi.org/10.30898/1684-1719.2025.11.39>