_____ КОМПЬЮТЕРНАЯ ГРАФИКА __ И визуализация

УДК 004.92

НЕЛОКАЛЬНЫЙ АЛГОРИТМ ШУМОПОДАВЛЕНИЯ С ИСПОЛЬЗОВАНИЕМ МЕТРИКИ СТРУКТУРНОГО СХОДСТВА

© 2019 г. А. А. Довганич^{*a*}, А. С. Крылов^{*a*,*}

^а Московский государственный университет имени М.В. Ломоносова Факультет вычислительной математики и кибернетики Лаборатория математических методов обработки изображений 119991 Москва, ГСП-1, Ленинские горы, д. 1, Россия

*e-mail: kryl@cs.msu.ru Поступила в редакцию 20.11.2018 г. После доработки 20.11.2018 г. Принята к публикации 16.02.2019 г.

Предлагается новый алгоритм шумоподавления на изображениях. Он является вариантом алгоритма нелокального среднего (NLM) с использованием метрики основанной на CMSC модификации индекса структурного сходства SSIM. Показана перспективность этой метрики для использования при построении весовой функции метода NLM с помощью разбиения на отдельные составляющие и задания физически обоснованной весовой функции для каждой компоненты. Результаты модифицированного метода сравниваются с существующим алгоритмом NLM, использующим для вычисления весов метрики L2 и SSIM.

DOI: 10.1134/S0132347419040022

1. ВВЕДЕНИЕ

Задача подавления шума на изображениях является одной из самых старых но, по-прежнему, актуальных [1—4]. Одновременно с ростом качества аппаратных средств съемки наблюдается не менее существенный рост и запросов по съемке в гораздо более сложных условиях. Можно привести следующие области применения, где необходимость подавления шума будет и в дальнейшем сохранять актуальность:

1. Съемка бытовыми камерами и смартфонами в условиях плохой освещенности или искусственного освещения. Запросы постоянно растут – сумерки, приглушенное освещение, неудачный спектр освещения.

2. Аэрокосмическая съемка Земли – растет желаемое пространственное разрешение. Сейчас вполне типичным является разрешение свыше 1 метра, тогда как типичная высота космического аппарата составляет около 1000 км, т.е. 1 пиксель видим под очень маленьким углом 10-6 радиан. Более того, т.к. космический аппарат движется со скоростью около 7000 м/с, то время экспозиции при съемке с таким разрешением не должно превышать 1/7000 секунды, что обуславливает крайне низкий световой поток.

3. В медицине изображения получаются, как правило, с помощью излучений вредных для здоровья — рентген, гамма излучение, микроволно-

вое излучение. Поэтому задача максимального снижения дозы облучения ведет опять к съемке в условиях слабого освещения и высоких шумов.

В принципе, подавляющее большинство алгоритмов представляет собой какой-либо вариант усреднения некоторого подмножества пикселей в некоторой окрестности рассматриваемой точки. Классический алгоритм среднего по окрестности это усреднение всех пикселей из прямоугольной или круглой окрестности точки. Линейные алгоритмы усреднения — это усреднение пикселей локальной окрестности, используя весовые функции (ядро операторы свертки), которые зависят только от расстояния от этих пикселей до рассматриваемой точки [2, 3]. Алгоритмы на основе анизотропной и нелинейной диффузии [5, 6] можно рассматривать как аналог сверточных линейных методов, но с ядром свертки, меняющимся по плоскости изображения, например, вблизи границ объектов, вытягивающимся вдоль границы. При этом, размытие происходит вдоль границ. а не поперек, эффективный размер ядра меняется в зависимости от сложности изображения. В однородных областях обеспечивается большее размытие и поэтому сглаживание шума; в информационно насыщенных областях степень размытия снижается, поэтому сохраняется больше как шума, так и деталей изображения.

В ранговых алгоритмах [7], которые относятся уже к нелинейным фильтрам, помимо отбора по расстоянию (форма окрестности), производится отбор и по яркости пикселей, в усреднении участвуют только пиксели, удовлетворяющие некоторым ограничениям.

Важным шагом развития подобных подходов являются методы самоподобия, как алгоритм нелокального среднего [8] (NLM) и ряд его разновидностей [9–11]. В усреднении участвуют только точки, у которых похожи малые локальные окрестности. Таким образом, отбор ведется не только по пространственному признаку или яркости, но и по паттерну, текстуре вокруг точки. Фактически используются предположения самоподобия (self-similarity) и усредняются похожие фрагменты. Дальнейшим развитием этого направления является алгоритм BM3D [12], который после отбора похожих фрагментов собирает их в трехмерную структуру и подвергает фильтрации Винера. Этот алгоритм на сегодняшний день считается наилучшим по качеству подавления шума, внося минимальные повреждения в изображение.

Для случая аддитивного Гауссового шума, за достаточно короткий период, одними из наиболее популярных методов подавления шума стали методы, использующие глубокое обучение. Они показывают достаточно конкурентные результаты в сравнении с методами усреднения [13, 14]. Однако необходимо отметить, что методы, основанные на самоподобии, более устойчивы к изменению типа шума и его однородности на изображении. В связи с этим необходимо отметить работу [4], в которой предлагают метод итерационного подавления шума как с использованием CNN, так и методов самоподобия.

В данной работе предлагается новый алгоритм шумоподавления основанный на модифицированном методе структурного сходства [15], который сравнивается с алгоритмом нелокального среднего с весовой функцией, предложенной в [7], а также с методами на основе метрик L2 и SSIM. Результаты сравнения показывают перспективность этой метрики для использования при построении весовой функции метода нелокального среднего с помощью разбиения на отдельные составляющие и задания физически обоснованной весовой функции для каждой компоненты, аналогично [7].

2. АЛГОРИТМ НЕЛОКАЛЬНОГО СРЕДНЕГО

Рассмотрим процедуру отбора похожих блоков в алгоритме нелокального среднего [8]:

$$I_{NLM}(x, y) =$$

$$= \frac{1}{W(x, y)} \sum_{x', y' \in \Omega(x, y)} w(x, y, x', y') I(x', y'), \quad (2.1)$$

где $W(x, y) = \sum_{x', y' \in \Omega(x, y)} w(x, y, x', y').$

Размер окрестности Ω здесь может быть произвольным, в том числе и всем изображением, откуда и идет название метода нелокальное среднее. Здесь w(x, y, x', y') — весовая функция, зависящая от схожести блоков с центрами в точках (x, y) и (x', y'), определенная как [8]:

$$w(x, y, x', y') =$$

$$= \exp\left(-1/(2\rho^{2}) \sum_{\xi,\eta\in\Omega_{p}} (I(x + \xi, y + \eta)) - (2.2) - I(x' + \xi, y' + \eta)^{2}\right).$$

Здесь окрестность Ω_p — это фрагмент изображения вокруг точки, по которому и выполняется сравнение похожести двух точек, т.е. анализ схожести их текстур или блоков. Числитель в экспоненте является, по сути, нормой L_2 разности двух векторов-параметров Ω_p , построенных как построчные выборки пикселей этих окрестностей.

Из анализа выше приведенных формул следует, что в силу использования нормы L_2 , блоки, содержащие совсем разные картинки, и блоки, содержащую одинаковую картинку, отличающуюся только яркостью или контрастом одинаково различны. При этом, мера отличия определяется только суммой квадратов разностей соответствующих пикселей и не зависит от графического образа картинки или структурного сходства блоков.

3. СТРУКТУРНЫЙ ИНДЕКС ПОДОБИЯ

Естественный способ преодолеть подобный недостаток — это подобрать более адекватную норму. В работе [16] предложен структурный индекс подобия SSIM, его достоинства по сравнению с L_2 рассмотрены в [17]. Он представляет собой произведение трех компонент:

SSIM(x, y, x', y') =

= l(x, y, x', y')c(x, y, x', y')s(x, y, x' y'),

где

$$l(x, y, x'', y') = \frac{2\mu(x, y)\mu(x', y') + C_1}{\mu^2(x, y) + \mu^2(x', y') + C_1},$$
 (3.2)

(3.1)

- функция подобия яркости,

$$c(x, y, x'', y') = \frac{2\sigma(x, y)\sigma(x', y') + C_2}{\sigma^2(x, y) + \sigma^2(x', y') + C_2},$$
 (3.3)

- функция подобия контраста,

$$s(x, y, x'', y') = \frac{\Gamma(x, y, x', y') + C_3}{2\sigma(x, y)\sigma(x', y') + C_3},$$
 (3.4)

функция подобия структуры.

Константы С1, С2, С3 введены исключительно для предотвращения деления на нуль и, в принципе, не обязательны, так как при численных расчетах подобные предосторожности могут быть выполнены и иными средствами, исходя из желаемого поведения соответствующих компонент при предельном стремлении к нулю величин из знаменателя. В формулах использованы следующие величины:

 $\mu(x, y) = \langle I(x, y) \rangle$ – средняя яркость,

 $\sigma^2(x, y) = \langle I^2(x, y) \rangle - \langle I(x, y) \rangle^2 -$ стандартное отклонение (корень из дисперсии), корреляционная функция – $\Gamma(x, y, x', y') = \langle I(x, y)I(x', y') \rangle$ – $\langle I(x, y)\rangle\langle I(x', y')\rangle.$

Усреднение $\langle . \rangle$ вычисляется по блоку Ω_p с центром в точке (*x*, *y*). Выражение s(x, y, x', y') зависит от корреляционной функции между двумя блоками с центрами в (x, y) и (x', y'), и представляет собой коэффициент корреляции между этими блоками. Отсюда видно, что:

$$0 \le l(x, y, x'', y') \le 1,$$

$$0 \le c(x, y, x'', y') \le 1,$$

$$-1 \le s(x, y, x'', y') \le 1.$$
(3.5)

В [16] предложен алгоритм нелокального среднего, использующий индекс структурного сходства как весовую функцию:

$$w(x, y, x', y') = SSIM(x, y, x', y').$$
(3.6)

Кроме того, формула NLM также претерпела изменения. Поскольку теперь каждый блок характеризуется раздельно яркостью, контрастом и структурой, логичным представляется перед выполнением усреднения центральных точек привести яркости и контрасты соответствующих блоков к целевому блоку. Поэтому

$$I_{SSIM}(x, y) = \frac{1}{W(x, y)} \sum_{x', y' \in \Omega(x, y)} w(x, y, x', y') J(x', y'),$$

$$J(x', y') = \frac{\sigma(x, y)}{\sigma(x', y')} (I(x', y') - \mu(x', y')) + \mu(x, y).$$
(3.7)

4. ПРЕДЛАГАЕМЫЙ МЕТОД

Молификации метода нелокального среднего. предложенная в [18] опирается на метрику SSIM, которая в свою очередь тоже не лишена недостатков. В статье [7] была предложена модификация метрики SSIM для задачи сравнения блоков изображений. Получена метрика MSSIM, которая при использовании в алгоритме нелокального среднего, показала результаты выше стандартного

ПРОГРАММИРОВАНИЕ Nº 4 2019 SSIM. Аргументация, которой мы руководствовались во время адаптации метрики SSIM в [7], была скорее эмпирическая и основывалась на особенностях работы алгоритма нелокального среднего. Полученная весовая имела следующий вид:

,

$$w(x, y, x', y') =$$

= $\Theta(T_1\mu(x, y)\mu(x', y') - (\mu^2(x, y) + \mu^2(x', y')) \times$
 $\times \Theta(T_2\sigma(x', y') - \sigma(x, y)) \times$
 $\times \Theta(s(x, y, x', y'))f(s(x, y, x', y')).$ (4.1)

Здесь $\Theta()$ – ступенчатая единичная функция Хэвисайда. Функция f() служит для регулирования крутизны учета влияния слабо коррелированных блоков, в настоящей работе эта функция полагается линейной, f(x) = x. Пороги T_1 и T_2 определяют допустимые пределы по отклонению яркости и контраста и задаются из априорных соображений о допустимом повышении шума. Например, для пятикратного разброса яркостей $T_1 = 5.2$.

В работе [15] автор анализирует метрики SSIM и MSE с более общих позиций, не применительно к алгоритму нелокального среднего. Он находит существенные недостатки в метрике SSIM. Данные недостатки способны повлиять на качество результата алгоритма шумоподавления, основанного на индексе структурного сходства. Например, SSIM нестабильна в окрестности нуля и сильно зависит от абсолютных значений входных параметров. Он предлагает несколько похожих метрик, в которых исправлены недостатки классического SSIM, объединяя их все под названием CMSC (composite similarity measure):

$$d_{1}(x, y, x', y') = \frac{(\mu(x, y) - \mu(x', y'))^{2}}{R^{2}},$$

$$d_{2}(x, y, x', y') = \frac{((\sigma(x, y) - \sigma(x', y'))^{2}}{(R/2)^{2}},$$

$$CMSC_{am}(x, y, x', y') =$$

$$= \left(1 - \frac{d_{1} + d_{2}}{2}\right)s(x, y, x', y'),$$

$$CMSC_{m}(x, y, x', y') =$$

$$= (1 - d_{1})(1 - d_{2})s(x, y, x', y'),$$

$$CMSC_{a}(x, y, x', y') = \frac{2}{3} - \frac{d_{1} + d_{2}}{3} + \frac{s(x, y, x', y')}{3},$$

(4.2)

где R — константа нормализациии, R = 255 для 8-битных изображений.

В данной работе рассмотрено примение метрики CMSC в алгоритме нелокального среднего. Предлагается модифицировать метрику, по которой производится сравнение блоков, и изменить вид весовой функции для модифицированного алгоритма нелокального среднего. Таким образом в формулу из предыдущего параграфа вместо

Изображение и тип шума	I04/Additive Gaussian Noise	I22/High Frequency Noise	I23/ Spatially Correlated Noise
PSNR			
Noisy image	24.4104	24.3689	24.6671
NLM-L2	31.0202	28.1615	34.5181
NLM-SSIM	30.4254	29.8546	31.1828
NLM-MSSIM	32.3352	30.3894	34.6982
NLM-CMSCam	33.1352	30.8629	35.0561
NLM-CMSCm	33.1401	30.8531	35.0496
NLM-CMSCa	33.1373	30.8603	35.0451
SSIM			
Noisy image	0.7691	0.6164	0.5892
NLM-L2	0.9212	0.8897	0.8893
NLM-SSIM	0.9446	0.9245	0.8964
NLM-MSSIM	0.9737	0.9358	0.9156
NLM-CMSCam	0.9768	0.9371	0.9251
NLM-CMSCm	0.9767	0.9373	0.9256
NLM-CMSCa	0.9768	0.9369	0.9258

Таблица 1. Результаты сравнения результатов методов шумоподавления по метрикам PSNR и SSIM

SSIM в качестве w(x, y, x', y') подставляются метрики MSSIM и CMSC.

Практически, внесенные изменения должны привести к следующим отличиям предлагаемого алгоритма от классического нелокального среднего [8] и основанного на SSIM [18].

1. В указанных алгоритмах в усреднении эффективно участвуют только точки блоков, похожих как по структуре, так и по яркости и контрасту. В предложенном алгоритме — от блоков с близкой структурой, при широком разбросе яркостей и контрастов. Усредняются все похожие фрагменты сцены, независимо от того на свету они или затенены.

2. Ограничение на допустимый разброс контрастов ведет к дополнительному снижению шума.

3. Отсутствие отрицательных весов в отличие от [18].

4. Более высокая стабильность метрики в окрестности нуля, позволит найти больше похожих блоков.

5. РЕЗУЛЬТАТЫ

Тестирование производилось на всех изображениях базы TID2013 [19] с различными типами шума. Алгоритм нелокального среднего для результатов на основе L2 обозначаем далее как NLM-L2; алгоритм, использующий индекс структурной схожести, обозначается как NLM-SSIM; метод с модифицированным индексом структурной схожести обозначен как NLM-MSSIM; методы на основе СMSC соответственно NLM-CMSCam, NLM- CMSCm, NLM-CMSCa. Для всех изображений базы наилучшие результаты были получены для метода с CMSC, несколько уступают ему метод NLM-MSSIM. Методы NLM-SSIM и NLM-L2 дают результаты более низкого качества. Блоки ищутся в окрестности с радиусом 7 пикселей, радиус каждого блока равен 3, то есть с учетом центрального пикселя диаметр блоков 3 + 1 + 3 = 7 пикселей, а размер 7 × 7 пикселей. При поиске похожих блоков их центры ищутся по окну 15 × 15 пикселей. Параметры C₁, C₂, C₃ заданы следующим образом: $C_1 = (k_1L), C_2 = (k_2L), C_3 = C_2/2$, где $k_1 = 0.01, k_2 = 0.03, L -$ динамический диапазон пикселей. Для NLM-L2 использовался параметр $\rho = 8.3$. Он выбирался исходя из параметров шума на изображении (стандартного отклонения). Результаты для нескольких характерных изображений приведены в таблице 1. Значения MOS (Mean Opinion Score) для изображений с шумом были следующие: I04/Additive Gaussian Noise -4.27, I22/ High Frequency Noise – 4.18, I23/Spatially Correlated Noise -3.26.

Подбор параметров производился при помощи расчета на сетке параметров и выбора наилучшего результата по метрике PSNR. Для NLM-L2 варьировался параметр ρ , для NLM-SSIM и NLM-MSSIM изменялись параметры C_1, C_2, C_3 . Также для всех методов менялись размеры блока и область поиска. Методы NLM-SSIM, NLM-MSSIM и NLM-CMSCam, NLM-CMSCm, NLM-CMSCa имеют лучшую производительность, чем NLM-L2. Разрыв производительности между ме-



Рис. 1. 104. а — Исходное изображение; б — Зашумленное изображение; в — NLM-L2; г — δ между NLM-L2 и зашумленным изображением в выделенной области; д — NLM-SSIM; е – δ между NLM-SSIM и зашумленным изображением в выделенной области; ж — NLM-MSSIM; з – δ между NLM-MSSIM и зашумленным изображением в выделенной области; и — NLM-CMSCm; к – δ между NLM-CMSCm и зашумленным изображением в выделенной области.

тодами еще больше возрастает при увеличении размеров блоков и диапазона поиска. Различия по эффективности метрик NLM-CMSCam, NLM-CMSCm, NLM-CMSCa между собой крайне малы, поэтому в дальнейшем изложении будем обозначать их NLM-CMSC.

Результаты в таблице представлены для изображений, соответствующих характерным классам. Изображение из первого примера представлено на рис. 1 (на рис. 1 и 2 разностные изображения отконтрастированы). Можно заметить, что эффективность NLM-MSSIM и NLM-CMSC по сравнению NLM-L2 возрастает на изображениях, которые имеют мелкие структурные элементы, которые не портятся в результате применения более эффективной метрики. Это можно видеть в области прически на рис. 1. Во втором примере из таблицы мелкие детали более разрознены, что почти уравнивает NLM-SSIM и NLM-MSSIM, но NLM-CMSC все еще показывает лучшие результаты. В последнем примере из таблицы, он изобра-



Рис. 2. 123. а – Исходное изображение; б – Зашумленное изображение; в – NLM-L2; г – δ между NLM-L2 и зашумленным изображением в выделенной области; д – NLM-SSIM; е – δ между NLM-SSIM и зашумленным изображением в выделенной области; ж – NLM-MSSIM; з – δ между NLM-MSSIM и зашумленным изображением в выделенной области; и – NLM-CMSCm; к – δ между NLM-CMSCm и зашумленным изображением в выделенной области; и – NLM-CMSCm; к – δ между NLM-CMSCm и зашумленным изображением в выделенной области.

жен на рис. 2, наоборот мелких деталей мало. Что делает это изображение благоприятным для применения классического NLM-L2, но благодаря участию блоков с близкой структурой при разбросе яркостей и контрастов NLM-MSSIM не проигрывает NLM-L2 в отличие от NLM-SSIM, а NLM-CMSC за счет устойчивости около нуля снова оказывается лидером.

6. ЗАКЛЮЧЕНИЕ

Проанализированы классический метод нелокального среднего и его модификация на основе метрики SSIM, рассмотрены достоинства и недостатки этих методов. Предложены новые методы шумоподавления на основе алгоритма нелокального среднего, использующего в качестве весовой функции метрики MSSIM и CMSC. Для базы изображений TID2013 [19] проведены сравнения с классическим алгоритмом нелокального среднего [2] и алгоритмом [18], использующим стандартный индекс структурной схожести. Наиболее универсальными себя показали алгоритмы на основе CMSC. Они показали лучшие или сопоставимые результаты на различных типах изображений. В то же время перспективной является модификация метода с весовой функцией на основе метрики MSSIM, используя идеи метода CMSC.

7. БЛАГОДАРНОСТИ

Исследование выполнено за счет гранта Российского научного фонда (проект № 17-11-01279).

СПИСОК ЛИТЕРАТУРЫ

- 1. *Buades A., Coll B., Morel J.M.* A review of image denoising algorithms, with a new one // Multiscale Modeling and Simulation. 2005. V. 4. № 2. P. 490–530.
- 2. Гонсалес Р., Вудс Р. Цифровая обработка изображений // М.: Техносфера, 2005. 1072 с.
- Ярославский Л.П. Цифровая обработка сигналов в оптике и голографии: Введение в цифровую оптику // М.: Радио и связь, 1987. 296 с.
- 4. *Cruz C. et al.* Nonlocality-Reinforced Convolutional Neural Networks for Image Denoising // arXiv preprint arXiv:1803.02112, 2018.
- Weickert J. Anisotropic Diffusion in Image Processing. ECMI Series, Teubner-Verlag, Stuttgart, Germany, 1998.
- Perona P., Malik J. Scale-space and edge detection using anisotropic diffusion // IEEE Transactions on pattern analysis and machine intelligence. 1990. V. 12. No. 7. P. 629–639.
- Довганич А.А., Крылов А.С., Юрин Д.В. Алгоритм нелокального среднего с использованием метрики, основанной на модифицированном индексе структурного сходства // GraphiCon 2018, 28-я Международная конференция по компьютерной графике и машинному зрению, 2018. С. 254–258.
- 8. *Buades A., Morel J.M.* A Non-Local Algorithm for Image Denoising // Computer Vision and Pattern Recog-

nition. IEEE Computer Society Conference on, IEEE. 2005. V. 2. P. 60–65.

- 9. Wang S., Xia Y., Liu Q., Luo J., Zhu Y., Feng D. Gabor feature based nonlocal means filter for textured image denoising // Journal of Visual Communication and Image Representation. 2012. V. 23. № 7. P. 1008–1018.
- 10. *Mamaev N.V., Lukin A.S., Yurin D.V.* HeNLM–LA: a Locally Adaptive Non-local Means Algorithm Based on Hermite Functions Expansion // Programming and Computer Software. 2014. V. 40. № 4. P. 199–207.
- 11. *Manzanera A*. Local Jet based similarity for NL-Means filtering // Pattern Recognition (ICPR), 20th International Conference on, IEEE. 2010. P. 2668–2671.
- Dabov K., Foi A., Katkovnik V., Egiazarian K. Image denoising by sparse 3D transform-domain collaborative filtering // IEEE Transactions on image processing. 2007. V. 16. № 8. P. 2080–2095.
- Zhang K., Zuo W., Chen Y., Meng D., Zhang L. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising // IEEE Transactions on Image Processing. 2017. V. 26. № 7. P. 3142–3155.
- Jin K.H., McCann M.T., Froustey E., Unser M. Deep convolutional neural network for inverse problems in imaging // IEEE Transactions on Image Processing. 2017. V. 26. № 9. P. 4509–4522.
- Palubinskas G. Mystery behind similarity measures MSE and SSIM // Image Processing (ICIP), IEEE International Conference on, IEEE. 2014. P. 575–579.
- Wang Z., Bovik A., Sheikh H., Simoncelli E.P. Image quality assessment: From error visibility to structural similarity // IEEE transactions on image processing. 2004. V. 13. № 4. P. 600–612.
- Wang Z. and Bovik A.C. Mean squared error: love it or leave it? – a new look at signal fidelity measures // IEEE signal processing magazine. 2009. V. 26. № 1. P. 98–117.
- Rehman A., Wang Z. SSIM-based non-local means image denoising // Image Processing (ICIP), 18th IEEE International Conference on, IEEE. 2011. P. 217–220.
- Ponomarenko N. et al. Color image database TID2013: Peculiarities and preliminary results // Visual Information Processing (EUVIP), 4th European Workshop on, IEEE. 2013. P. 106–111.

8