

УДК 004.032.26

АНАЛИТИЧЕСКИЙ ОБЗОР МЕТОДОВ УДАЛЕНИЯ ШУМОВ НА ИЗОБРАЖЕНИЙ



А.А. Климбасов.
студент гр. 950501,
кафедра ЭВМ, БГУИР



О.А. Найдович
студент 2 курса,
специальность Прикладная
математика, ФПМИ, БГУ



Д.Ю. Перцев
кандидат технических наук,
кафедра ЭВМ, БГУИР

Белорусский государственный университет информатики и радиоэлектроники, Республика Беларусь.
E-mail: pertsev@bsuir.by, o.naidovich@gmail.com, klimbasov.al@gmail.com.

Д. Ю. Перцев

Окончил аспирантуру Белорусского государственного университета информатики и радиоэлектроники (2016), защитил диссертацию в совете 05.13.01 (2020). Является доцентом кафедры ЭВМ.

А. А. Климбасов

Является студентом Белорусского государственного университета информатики и радиоэлектроники по специальности 1-40 02 01 «Вычислительные машины, системы и сети».

О. А. Найдович

Является студентом Белорусского государственного университета факультета прикладной математики и информатики, специальность: «Прикладная математика».

Аннотация. Проанализированы виды шумов на изображении, а также методы их устранения. Выбраны наиболее перспективные подходы, представлены результаты оценки основных метрик (PSNR и SSIM) для тестовых наборов данных SSID и DND.

Ключевые слова: Шумоподавление, Глубокие нейронные сети, DnCNN, FFDNet, IRCNN, SRND.

Введение.

Влияние окружающей среды на пленку, несовершенство кино – и фотооборудования, ошибки, возникающие в системах хранения данных, и многие другие факторы приводят к неизбежному загрязнению изображения шумами и, как следствие, приводит к потерям информации и четкости. С другой стороны, наличие шумов на картинке может ухудшить точность решения многих фундаментальных задач компьютерного зрения, таких как сегментация и классификация объектов, их обнаружение и отслеживание. Таким образом, решение задачи шумоподавления играет важную роль в современных системах обработки видеопотока.

Для решения поставленной проблемы разрабатываются различные методы, которые должны не просто убрать шум с изображения, но и при этом избежать потери качества самой картинке. Поскольку шум по своим характеристикам сложно отличим от объектов, текстуры и других деталей изображения, его затруднительно выделить и удалить, в силу чего изображение после шумоподавления может потерять некоторые детали.

К настоящему времени существует широкий круг подходов к удалению шумов, каждый из которых обладает своими преимуществами и недостатками. Однако задача не тривиальна и не имеет единственно верного решения как с математической, так и с архитектурной точки зрения. Как следствие, исследования в этой сфере не прекращаются, и она остается открытой для новых уникальных идей.

Шумы на изображении.

Задача шумоподавления состоит в том, чтобы уменьшить шумы на изображении, но при этом максимально сохранить оригинальные данные. В целом можно выделить следующие основные требования к процессу:

- шум должен быть минимизирован;
- гладкие контуры объектов не должны быть искажены;
- края объектов должны сохранить резкость;
- текстура изображения должна быть сохранена;
- новые артефакты не должны создаваться.

Математически проблема шумоподавления может быть сформулирована следующим образом:

$$y = x + n \quad (1)$$

где y – изображение с шумом, x – не зашумлённое изображение, n – аддитивный белый гауссовский шум (англ. Additive white Gaussian noise, AWGN) со стандартным отклонением σ [1].

Попытки решить задачу из уравнения (1) не имеют смысла, так как шум во многом схож с разными элементами изображения и может изменяться по характеристикам в зависимости от вида шума. Типичными видами шума на изображении являются Гауссовский шум [2], соль и перец (англ. Salt and Pepper), шум Пуассона и другие. Однако исследования в данной области породили методы, решающие данную проблему, с некоторой погрешностью. Анализируя такие методы, можно выделить следующие группы: методы на основе анализа некоторой окрестности, на основе преобразования изображения в другую область, глубокие нейронные сети.

Методы на основе анализа некоторой окрестности.

Данные методы шумоподавления направлены на удаление шума путем вычисления корреляции между соседними пикселями или их группой. На основе корреляции в дальнейшем вычисляются новое значение. В общем случае, данный подход можно разделить на две группы: методы пространственной фильтрации и вариационные методы шумоподавления.

Пространственная фильтрация изображений [3] – это метод предварительной фильтрации изображения, при котором обработка происходит посредством применения некоторого оператора последовательно к каждой точке изображения. Поскольку фильтрация является одним из основных способов обработки изображений, для уменьшения шума было создано множество пространственных фильтров, которые можно разделить на два типа, – линейные и нелинейные.

Линейные фильтры являются наиболее старыми из применяемых, например, фильтрация по среднему значению. Она хорошо справляется с Гауссовским шумом, однако слишком сильно сглаживает изображения с высоким стандартным нормальным распределением шумов. Эту проблему частично решила фильтрация Винера, однако ее основной недостаток – проблемы в области резкого изменения контекста.

Большее распространение сейчас имеют нелинейные методы фильтрации, например, медианная фильтрация, взвешенная медианная фильтрация и билатеральный фильтр. Данные фильтры показывают высокое качество удаления шума, однако производительность этих методов очень низкая, что делает их неэффективными.

Методы шумоподавления на основе преобразования изображения в другую область.

Среди данных методов шумоподавления можно выделить преобразование Фурье, косинусное преобразование, Вейвлет-преобразование [4, 5], а также трехмерную фильтрацию (англ. Block-matching and 3D filtering, BM3D) [6]. Основным смыслом трансформации изображения заключается в том, что после ее применения характеристики незашумленного изображения будут сильно отличаться от характеристик шума, что позволит легко выявить зашумленные места.

В отличие от предыдущей группы методов, зашумленное изображение преобразуется в другую область (например, частотную), затем применяется процедура удаления шума к

преобразованному изображению в соответствии с алгоритмом. Способы преобразования изображения могут быть разделены согласно выбранному базису функции.

Одним из самых распространённых представителей такого подхода является VM3D (двухэтапный коллаборативный фильтр). Данный метод сохраняет одинаковые части картинки в 3D группах, после чего преобразует их в вейвлет-область, применяет фильтр Винера [7]. Затем области преобразуются обратно и обрабатываются согласно полученной оценке. Однако с увеличением количества шума падает и качество работы метода, а также появляются артефакты, особенно в однотонных однородных областях.

Методы шумоподавления на основе нейронных сетей.

В последнее время методы, основанные на нейронных сетях, показывают хорошую производительность во многих задачах компьютерного зрения, в том числе, и удаления шума. Разработаны state-of-the-art методы моделей нейронных сетей, которые превосходят по производительности рассмотренные ранее методы и подходы. При этом можно выделить два крупных класса сетей – модели многослойного перцептрона (англ. Multilayered perceptron, MLP [8]) и модели сверточных нейронных сетей.

Модели многослойного перцептрона имеют свои преимущества в некоторых областях машинного обучения, однако для решения задачи удаления шума они не подходят в силу архитектурной специфики, так как для обработки изображения необходимо перевести матрицу-картинку к одномерному вектору. Из-за этого сеть становится громоздкой и труднообучаемой. Более того, для ее обучения потребуется большое количество размеченных данных. Однако данная проблема эффективно решается с использованием сверточных нейронных сетей благодаря особенности их архитектуры.

Сверточная нейронная сеть DnCNN (рисунок 1) разработана Харбинским технологическим институтом и Гонконгским политехническим университетом [9, 10].




Рисунок 1. Архитектура нейронной сети DnCNN

Сеть предназначена для удаления Гауссовского шума с любым стандартным нормальным распределением и улучшения резкости изображения. В ее состав входит три вида блоков:

- блок, состоящий из сверточного слоя (64 фильтра размером $3 \times 3 \times C$, где C – это количество цветов, составляющих изображение) и функции активации (ReLU);
- блок, состоящий из сверточных слоев с фильтрами $3 \times 3 \times 64$. Перед каждой сверткой применяется пакетная нормализация и функция активации ReLU;
- блок, представляющий из себя сверточный слой размером $3 \times 3 \times 64$. Данный блок применяется для восстановления выходных данных, поэтому он находится в конце нейронной сети.

Сверточная нейронная сеть FFDNet [11, 12] (рисунок 2) с точки зрения архитектуры похожа на DnCNN.




Рисунок 2. Архитектура сверточной нейронной сети FFDNet

Блок на входе распределяет входное изображение в соответствии с разрешением изображения. Это позволяет уменьшить сложность алгоритма. Слой на выходе восстанавливает нелинейную выходную информацию к разрешению картинки на момент входа. Данное усовершенствование предназначено для поиска оптимального решения по сложности архитектуры и качеству выходных данных.

На рисунках 3 и 4 показаны архитектуры родственных сверточных нейронных сетей.




Рисунок 3. Архитектура сверточной нейронной сети IRCNN




Рисунок 4. Архитектура сверточной нейронной сети SRND

Сравнение моделей нейронных сетей

Результаты удаления шума с изображений можно оценить с помощью визуальной оценки и с помощью специальных метрик.

Визуальный анализ плохо поддается математическому описанию. Основные критерии, по которым выполняется оценка визуального анализа, – это остаточная зашумленность картинки, резкость острых граней и сохранность текстур.

Метрики, в свою очередь, устанавливают строгую математическую зависимость между чистой и зашумленной картинкой. В области шумоподавления широко используются PSNR [13] и SSIM [14], определяемые по формулам (2) и (4) соответственно.

$$\text{PSNR}(x, \hat{x}) = 10 * \log_{10} \left(\frac{\text{MAX}^2}{\text{MSE}} \right). \quad (1)$$

$$\text{MAX.MSE} \quad (2)$$

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (x - \hat{x})^2, \quad (3)$$

где x – это оригинальное значение пикселя изображения до зашумления, \hat{x} – это значение пикселя, полученное после применения алгоритма уменьшения шумов.

$$SSIM(x, \hat{x}) = \frac{(2\mu_x \mu_{\hat{x}} + c_2)(2\sigma_{x\hat{x}} + c_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + c_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + c_2)}, \quad (4)$$

где $\mu_x, \mu_{\hat{x}}$ – математическое ожидание для x и \hat{x} соответственно, σ_x^2 и $\sigma_{\hat{x}}^2$ – дисперсия для x и \hat{x} соответственно, $\sigma_{x\hat{x}}$ – ковариация x и \hat{x} , c_1, c_2 – константы, зависящие от диапазона рассматриваемой области вокруг пикселя.

Сравнение методов удаления шума с изображений, основанный на CNN

В качестве набора данных используются тестовые наборы SSID и DND. В таблицах 1 и 2 приведены результаты измерения SSIM и PSNR, а также усредненные значения результатов для следующих сверточных нейронных сетей – DnCNN, FFDNet, IRCNN, SRND. Примеры результатов обработки показаны в таблице 3.

Таблица 1. Результаты измерения SSIM и PSNR для тестовых наборов SSID и DND

$\sigma = 50$		DNCNN	FFDNet	IRCNN	SRMD
SIDD	PSNR	23.66	26.30	38.71	32.96
	SSIM	0.583	0.753	0.951	0.822
DND	PSNR	32.43	33.07	39.26	35.01
	SSIM	0.790	0.834	0.953	0.854


Таблица 2. Усреднённые результаты измерения SSIM и PSNR для тестовых наборов, представленных в таблице 3

$\Sigma = 50$	DNCNN	FFDNet	IRCNN	SRMD
PSNR	31.60	32.03	31.67	30.75
$\Sigma = 50$	DNCNN	FFDNet	IRCNN	SRMD
SSIM	0.8690	0.8799	0.8714	0.8526

Заключение.

С ростом активности применения нейросетей глубокого обучения резко возросло количество исследований в данной области и, как результат, качество их работы. В связи с этим они используются шире, чем алгоритмические методы и имеют ряд преимуществ над ними. Однако перед данным подходом возникает проблема сложности получения размеченных данных для обучения выбранной нейронной сети. В большинстве своём обучаются такие сети на искусственно зашумленных изображениях и качество их последующей работы на фотографиях из реального мира сильно зависит от совпадения характеристик реальных шумов с наложенными искусственно на стадии обучения.

Таблица 3. Примеры результатов обработки зашумленных изображений

					
					
					
					
					
					
					
Зашумленное изображение	DnCNN	FFDNet	IRCNN	SRMD	оригинальная картинка

Список литературы

- [1] Standard deviation [Electronic Resource] / Wikipedia. – Mode of access: https://en.wikipedia.org/wiki/Standard_deviation.
- [2] Chapter 9. Noise [Electronic Resource] / MIT. – Mode of access: https://mitocw.ups.edu.ec/courses/electrical-engineering-and-computer-science/6-02-introduction-to-eecs-ii-digital-communication-systems-fall-2012/readings/MIT6_02F12_chap09.pdf.
- [3] Чичварин, Н. Пространственная фильтрация изображений / Н. Чичварин // Национальная библиотека им. Н. Э. Баумана – ISSN 2542-0356.
- [4] Generalized Wiener filtering Computational Techniques [Electronic Resource] / William K. Pratt. – Mode of access: <http://dfmf.uned.es/~daniel/www-imagen-dhp/biblio/wiener-filtering-general.pdf>.
- [5] William K. Generalized Wiener Filtering Computation Techniques / K. William // IEEE Transactions on Computers. – 1972. – Volume: C-21, Issue: 7. DOI: 10.1109/t-c.1972.223567.
- [6] Dabov, K. Image denoising by sparse 3D transform-domain collaborative filtering. / K. Dabov, A. Foi,

V. Katkovnik, K. Egiazarian // IEEE Transactions on Image Processing. – 2014. – Volume 16. - Issue 8. - P. 2080–2095. DOI: 10.1109/TIP.2007.901238.

[7] Восстановление изображения с помощью фильтрации Винера [Электронный ресурс] / Habr – Режим доступа: <https://habr.com/ru/post/424987>. - Дата доступа: 01.10.2018.

[8] Machine Learning: Multi Layer Perceptrons [Electronic Resource] / Albert-Ludwigs-University Freiburg. – Mode of access: http://ml.informatik.uni-freiburg.de/former/_media/teaching/ss10/05_mlps.printer.pdf.

[9] Ch, S. Residual learning of deep convolutional neural networks for image denoising / S. Ch, O. Jun, G. Xiring // Journal of Intelligent and Fuzzy Systems. – 2019. – Volume 37. – Issue 2. – P. 2809-2818. DOI:10.3233/JIFS-190017.

[10] Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising [Electronic Resource] / GitHub. – Mode of access: <https://github.com/cszn/DnCNN>.

[11] Kai, Z. FFDNet: Toward a Fast and Flexible Solution for CNN based Image Denoising / Z. Lei, Z. Wangmeng, Z. Kai // IEEE Transactions on Image Processing – 2018. – Volume 27. Issue 9 DOI: 10.1109/TIP.2018.2839891.

[12] Matias, T. An Analysis and Implementation of the FFDNet Image Denoising Method. / T. Matias, D. Julie, V. Thomas // Image Processing On Line. – 2019. – Volume 9. – P. 1-25. DOI: 10.5201/ipol.2019.231.

[13] Structural Similarity Index SSIMplified [Electronic Resource] / ArXiv.org. – Mode of access: <https://arxiv.org/ftp/arxiv/papers/1503/1503.06680.pdf>.

[14] Peak signal-to-noise ratio PSNR [Electronic Resource] / Wikipedia. – Mode of access: https://en.wikipedia.org/wiki/Peak_signal-to-noise_ratio.

ANALYTICAL REVIEW OF METHODS FOR NOISE reduction IN IMAGES

A.A. KLIMBASAU

*student of group 950501,
Computer Science Department,
BSUIR*

O. A. NAIDOVICH

*student of 2 course,
Applied Mathematics Department,
FAMCS, BSU*

D. PERTSAU

*PhD, Computer Science
Department, BSUIR*

*Belarusian State University of Informatics and Radioelectronics, Republic of Belarus
E-mail: pertsev@bsuir.by*

Abstract. The types of noise in the image are analyzed, as well as methods for their elimination. The most promising approaches are selected; the results of evaluating the main metrics (PSNR and SSIM) for SSID and DND datasets are presented.

Keywords: Noise reduction, Deep neural networks, DnCNN, FFDNet, IRCNN, SRND.