

УДК 519.688

Восстановление неравномерно освещенных изображений

А.А. Сапегин

Научный руководитель: А.Д. Брагин

Национальный исследовательский Томский политехнический университет,
Россия, г. Томск, пр. Ленина, 30, 634050

E-mail: aas271@tpu.ru

Restoration of unevenly illuminated images

A.A. Sapegin

Scientific Supervisor: A.D. Bragin

Tomsk Polytechnic University, Russia, Tomsk, Lenin str., 30, 634050

E-mail: aas271@tpu.ru

Abstract. *In this paper, we will look at one of the ways to solve the problem of restoring unevenly illuminated images by using convolutional neural network. The article describes the algorithm for preparing data for model training and the process of evaluating the visual quality of images.*

Key words: *convolutional neural network, brightness normalization, image enhancement*

Введение

Одной из главных проблем изображений, полученных при естественном освещении, является неравномерное распределение яркости и теней. Это может привести к потере деталей в темных или светлых областях изображения, искажению цветов и контраста, а также затруднить обработку изображения и его анализ.

Целью данной работы является разработка алгоритма по нормализации яркостных характеристик неравномерно освещенного изображения.

Экспериментальная часть

В качестве подхода к поставленной задаче было выбрано использование сверточной нейронной сети архитектуры SRCNN (Super Resolution Convolution Neural Network) [1]. Модель используется для увеличения разрешения изображения и имеет особенность в виде того, что сеть обрабатывает изображение, которое уже было увеличено при помощи бикубической интерполяции. Обработку изображения нейросетью можно условно разделить на три этапа: извлечение признаков (преобразование фрагментов изображения в многомерные вектора), нелинейное преобразование (нелинейное отображение каждого многомерного вектора на другой многомерный вектор), реконструкция (получение значения яркости центрального пикселя на основе полученных признаков).

Работу сети с признаками, которые она извлекает, можно адаптировать под различные задачи, в том числе и под задачу выравнивания яркости и контраста изображения.

Одной из основных проблем данного подхода, является отсутствие данных для обучения модели. При решении задачи повышения разрешения на вход сети подавалась уменьшенное и снова увеличенное изображение, а результат сравнивался с исходным. В случае же нормализации яркости возникают трудности с подбором эталонов, в виду того, что эталон должен быть правильно проэкспонирован, то есть в кадре не должно быть сильно темных или же сильно светлых областей.

Помимо этого необходимо подобрать правильные методы аугментации эталона, для формирования сета, который будет подаваться на вход сети во время обучения. Изначально предполагалось, что на вход будет подаваться низкоконтрастная версия эталона с пониженной либо повышенной яркостью. Подготовленная таким образом сеть лишь слегка увеличивала яркость и резкость изображения.

Итоговым решением стало использование датасета, рассчитанного на обучение нейросетей по удалению теней. На вход подавалось изображение с тенью, а в качестве эталона – фото без тени. Данный подход также решал проблему возможной неправильной экспозиции в кадре, т.к. для подобных задач кадр выстраивается определенным образом, чтобы на входных изображениях тень могла быть четко идентифицирована. Как и в предыдущем подходе к входным данным применялась корректировка яркости и контраста для их ухудшения (далее эти изображения будут называться «условный оригинал»).

Однако, даже если по аналогии с предыдущим подходом применять яркостную аугментацию для входных данных, то результирующие изображения сильно теряли в четкости. Было принято решение применить к эталону метод выравнивания гистограммы CLAHE (Contrast Limited Adaptive Histogram Equalization) [2]. Благодаря данному подходу удалось повысить резкость обработанного моделью изображения.

Также в рамках экспериментов был опробован подход, который заключается в подаче на вход нескольких изображений: условного оригинала и его обработанные версии. Модификация SRCNN, которая обрабатывает два изображения, называется 2DSRCN, три – 3DSRCN [3]. В качестве методов обработки были выбраны упомянутый выше CLAHE, а также Single-Scale Retinex (SSR) [4]. Для обучения 3DSRCN использовались все три версии изображений, а в случае архитектуры 2DSRCN было подготовлено две версии сети, которым на вход подавался условный оригинал и одна из его обработанных версий.

Результаты

Для оценки качества работы моделей использовалась оценка Мунтеану-Роса [5], которая вычисляется по следующей формуле:

$$f_{MR} = \ln(\ln(E + e)) + \frac{\tau}{MN} + e^H,$$

$$H = - \sum_{i=0}^{255} l_i \ln(l_i),$$

где E – суммарная интенсивность пикселей на контурах изображения; e – число Эйлера; τ – количество пикселей на контурах; N и M – соответственно ширина и высота изображения; l_i – доля пикселей с i -м уровнем яркости. Контур изображения определяется с помощью оператора Собеля [6]. Оценка Мунтеану-Роса основана на том свойстве, что для человеческого восприятия большее значение имеет перепад яркости в соседних пикселях, чем значение яркости в каждом пикселе. В то же время равномерность гистограммы изображения также положительно сказывается на восприятии изображения.

Помимо результатов работы обученных моделей производилась оценка стандартных методов улучшения контраста изображений, таких как глобальное выравнивание гистограммы (GHE) [6] и Multi-Scale Retinex (MSR) [4]. Итоговые результаты представлены в таблице 1.

Таблица 1

Оценка Мунтеану-Роса

Оригинал	GHE	MSR	SRCNN	2DSRCN (оригинал и SSR)	2DSRCN (оригинал и CLAHE)	3DSRCN
218	400	373	660	425	477	469

Как можно видеть из таблицы, простая версия SRCNN имеет самое высокое значение целевой метрики. Однако при визуальной оценке результатов можно заключить, что сильное повышение различимости объектов сопровождается появлением артефактов в виде ступенчатых перепадов [6], что продемонстрировано на рисунке 1.

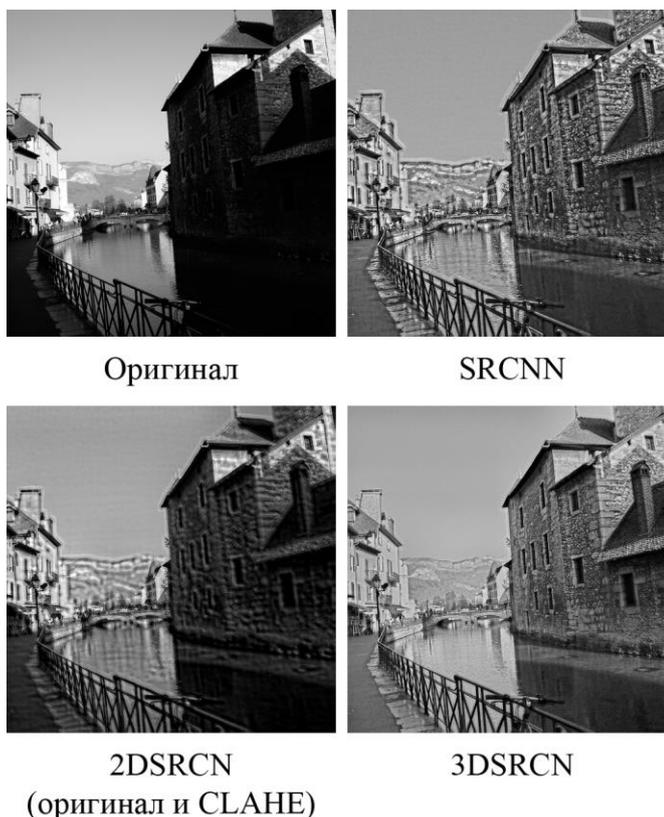


Рис. 1. Примеры работы моделей

Заключение

В результате проведенных исследований был выявлен оптимальный подход к нормализации яркостных характеристик с помощью использования архитектуры сверхточной нейронной сети 3DSRCN. Данный способ позволяет добиться высокой степени различимости объектов при достаточно низком риске возникновения артефактов, свойственных изображениям после процедуры нормализации яркости.

Список литературы

1. Dong, C., Loy, C.C., He, K., Tang, X. Image super-resolution using deep convolutional networks // IEEE transactions on pattern analysis and machine intelligence. – 2015. – P. 295–307.
2. Кокошкин А.В., Коротков В.А., Новичихин Е.П. Модификация метода CLAHE для компенсации влияния гидрометеоров // Журнал Радиоэлектроники [электронный журнал], – 2017. – Т.10. – URL: <http://jre.cplire.ru/jre/oct17/10/text.pdf>.
3. Nayat K. Super-Resolution via Deep Learning // arXiv.org [электронный архив] – 2017. – URL: <https://arxiv.org/abs/1706.09077v1>.
4. Jobson D.J., Rahman Z., Woodell G.A. A multiscale retinex for bridging the gap between color images and the human observation of scenes // IEEE Trans. Image Process. – 1997. – Vol. 6, № 7. – P. 965–976.
5. Munteanu C., Rosa A. Gray-scale image enhancement as an automatic process driven by evolution // IEEE Trans. on Systems, Man, and Cybernetics – part B: Cybernetics. – 2004. – Vol. 34, № 2.
6. Гонсалес Р., Вудс Р. Цифровая обработка изображений. – Москва : Техносфера, 2005. – 1072 с.