

ВОССТАНОВЛЕНИЕ НЕРАВНОМЕРНО ОСВЕЩЕННЫХ ИЗОБРАЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Сапегин А.А.

Национальный исследовательский Томский политехнический университет, ИШИТР, 8ИМ21,
e-mail: aas271@tpu.ru

Аннотация

В работе рассматривается способ решения проблемы восстановления неравномерно освещенных изображений путем нормализации яркости с использованием сверточной нейронной сети. Представлены алгоритмы подготовки данных для обучения модели и процесс оценки визуального качества изображений.

Ключевые слова: сверточная нейронная сеть, нормализация яркости, улучшение изображения

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 контраста, а также затруднить обработку изображения и его анализ. Методы для решения данной проблемы, как например Multi Scale Retinex (MSR) [1], требуют подбор параметров под каждую ситуацию в отдельности, в то время как более универсальные методы могут часто выдавать невалидные результаты.

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

Описание алгоритма

В качестве подхода к решению поставленной задачи было выбрано использование сверточной нейронной сети архитектуры SRCNN (Super Resolution Convolution Neural Network). 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 [2]: 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). Данные этапы на примере архитектуры сети проиллюстрированы на рис. 1.




Рис. 1. Архитектура SRCNN

Подход с использованием выбранной архитектурой заключается в адаптации работы сети с извлеченными признаками для задачи выравнивания яркости и контраста изображения.

Экспериментальная часть

Одной из основных сложностей, с которой можно столкнуться, при попытке адаптации сети к новой задаче – отсутствие подходящих данных для обучения модели. Эталон, с которым должны

сравниваться результаты работы сети, должен быть правильно проэкспонирован, то есть в кадре не должно быть сильно темных или же сильно светлых областей. При этом на вход необходимо подавать «испорченную» версию изображения. Изначально предполагалось, что в качестве последней будет использована низкоконтрастная версия эталона с пониженной либо повышенной яркостью. Обученная таким образом сеть лишь слегка увеличивала яркость и резкость изображения.

Итоговым решением стало использование набора данных, рассчитанного на обучение нейросетей по удалению теней. При таком подходе имеется подходящий эталон с правильно подобранным освещением и входные изображения с «проблемными областями». Однако для того, чтобы сеть не пыталась исправить яркость только в темных областях, необходимо также использовать яркостную и контрастную аугментацию для входных данных.

Так как даже в таком случае результаты работы сети получались тусклыми, было принято решение применить к эталону метод выравнивания гистограммы CLAHE (Contrast Limited Adaptive Histogram Equalization) [3]. Таким образом, удалось добиться повышения резкости обработанного моделью изображения.

Также в рамках экспериментов были опробованы подходы с подачей на вход не только «испорченных» изображений, но и их версий, обработанных другими алгоритмами (CLAHE [3] и Single-Scale Retinex (SSR) с нормализацией гистограммы [4]). Модифицированные архитектуры сети имеют названия в соответствии с тем, какое количество изображений подается на вход: 3DSRCN [5] для модели, принимающей 3 канала и 2DSRCN для модели, принимающей 2 канала. Для итоговой оценки брались две вариации 2DSRCN, каждая из которых принимала на вход оригинал и его обработанную одним из двух описанных выше алгоритмов версию. На вход же 3DSRCN подавался оригинал и его обе обработанные версии.

Оценка результатов работы

В качестве основной оценки работы модели используется оценка Мунтеану-Роса (MR) [6], 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. Контурные изображения определяются с помощью оператора Собеля [7].

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.

Главным недостатком данной оценки является то, что она практически никак не учитывает артефакты, которые могут возникнуть в результате работы алгоритмов. Итоговое изображение никак не штрафуются за их наличие при подсчете метрики. Из-за этого могут возникать ситуации, при которых модель или алгоритм высоко оцениваются, но при этом полученное изображение непригодно для восприятия.

В качестве вспомогательной метрики на текущий момент используется индекс структурного сходства SSIM [8]. Результаты работы алгоритмов сравниваются с оригиналом. Данная оценка показывает, насколько сильно было искажено изображение после его обработки.

Результаты работы

В таблице 1 сравниваются результаты работы выравнивания гистограммы (GHE) [7], MSR [1], переобученной SRCNN и трех ее модификаций: двух и одной 3DSRCN. Помимо классической метрики MR использовалась ее модификация, исключая влияние гистограммы на оценку.

Оценка работы алгоритмов

	Оригинал	GHE	MSR	SRCNN	2DSRCN (оригинал и SSR)	2DSRCN (оригинал и CLAHE)	3DSRCN
MR	546	1686	1153	1660	898	1244	1147
MR _{mod}	218	400	373	660	425	477	469
SSIM	1	0.75	0.86	0.59	0.76	0.65	0.75

На рис. 1 продемонстрированы результат работы алгоритма в виде изображений и их гистограмм, показывающих количественное распределение пикселей разной яркости (диапазон значений от 0 до 255).




Рис. 1. Результаты работы алгоритмов

Как видно из рисунка и таблицы GHE и SRCNN имеют наибольшую метрику MR. Однако если в первом случае преимущество явно достигается за счет равномерной формы гистограммы, то нейросеть значительно повышает резкость изображения и видимость деталей, что в свою очередь приводит к появлению артефактов и также вредит восприятию композиции.

Заключение

В результате проведенных исследований был проанализирован подход к восстановлению яркостных характеристик изображения с неравномерным распределением. Из различных вариаций данного подхода использование архитектуры 3DSRCN является наиболее компромиссным решением задачи. Его использование позволяет сильно повысить четкость объектов, не приводя к возникновению артефактов, что достигается путем баланса метрик MR и SSIM. Модель достаточно сильно искажает исходное изображение в сравнении с MSR и имеет склонность к концентрации плотности распределения яркостей в конкретной зоне (на рисунке 1 видно, что у обработанного нейросетью изображения имеется большое количество пикселей в диапазоне яркости от 150 до 175). Это может привести к эффекту видимости плоского рельефа вместо объемного объекта. Данный эффект может мешать восприятию глубины некоторых участков, однако контуры все еще будут различимы.

Список использованных источников

1. 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.
2. 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.
3. Кокошкин А.В., Коротков В.А., Новичихин Е.П. Модификация метода CLAHE для компенсации влияния гидрометеоров // Текст: электронный // Журнал Радиоэлектроники. – 2017. – 10. – URL: <http://jre.cplire.ru/jre/oct17/10/text.pdf>.
4. Parthasarathy S, Sankaran P. An automated multi-Scale Retinex with Color Restoration for image enhancement // Текст: электронный // ResearchGate. – 2012. – URL: https://www.researchgate.net/publication/254024214_An_automated_multi_Scale_Retinex_with_Color_Restoration_for_image_enhancement
5. Hayat K. Super-Resolution via Deep Learning // Текст: электронный // arXiv.org – 2017. – URL: <https://arxiv.org/abs/1706.09077v1>.
6. 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.
7. Гонсалес Р., Вудс Р. Цифровая обработка изображений. – Москва: Техносфера, 2005. – 1072 с.
8. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P Image Quality Assessment: From Error Visibility to Structural Similarity // IEEE Trans. Image Process. – 2004. – Vol. 13. – № 4. – P. 2–15.