

ОБРАБОТКА НОЧНЫХ СНИМКОВ С ИСПОЛЬЗОВАНИЕМ МОДИФИКАЦИИ ГАММА-КОРРЕКЦИИ

Санегин А.А.

Томский политехнический университет, ИШИТР, аспирант, гр. А4-39,
e-mail: aas271@tpu.ru

Аннотация

В данной работе рассматривается способ решения проблемы обработки ночных снимков путем применения методов машинного обучения для автоматизации процесса локальной гамма-коррекции. Представлены алгоритмы подготовки данных для обучения модели и процесс оценки визуального качества снимков.

Ключевые слова: нормализация яркости, ночная съемка, гамма-коррекция

Введение

Ночная съемка традиционно представляет собой одну из наиболее сложных задач, как для аппаратных возможностей фотографической техники, так и для программных алгоритмов постобработки.

Данный вид съемок проводится в условиях недостаточной освещенности, как правило, не превышающей 50 лк [1]. Подобные условия приводят к потребности тщательной индивидуальной настройки параметров съемки и обработки для каждого конкретного случая.

В данной работе рассматривается задача модернизации уже существующих способов подготовки цифровых снимков путем внедрения гибридизации с методами машинного обучения. В рамках конкретного исследования рассмотрена возможность модернизации востребованного метода гамма-коррекции: увеличение качества обработки при сохранении низкой затрачиваемой ресурсов.

Описание метода

Снимок – частный случай изображения, представляющий собою результат съёмки реального мира с помощью фототехники. Тем самым, любые методы по обработке изображения применимы к снимкам. Одним из таких методов, является гамма-коррекция.

Гамма-коррекцию можно отнести к частному случаю редактирования кривой. Данный инструмент распространен в графических редакторах и позволяет точно управлять яркостью и контрастом цифрового изображения, изменяя распределение тонов от теней до светов. Сама по себе кривая является графиком, на оси абсцисс которого отмечена исходная яркость пикселей изображения (от 0 до 255), а на оси ординат – новая яркость после редактирования. Первичная форма графика – прямая линия под углом 45°. При изменении формы данной линии меняется яркость и контраст в разных участках изображения.

Гамма-коррекция сильно упрощает данный процесс, сводя все к необходимости подбора параметра γ (гамма). В этом подходе значение выходного пикселя вычисляется как степень исходного, согласно формуле:

$$y = 255 \times \left(\frac{x}{255} \right)^{\frac{1}{\gamma}}$$

где x – интенсивность пикселя перед коррекцией, а y – интенсивность пикселя после коррекции.

При значениях γ выше единицы, изображение становится темнее, и, соответственно, при значениях ниже единицы – становится ярче.

В контексте обработки именно снимков, гамма-коррекция имеет недостаток в виде возможной потери информации при ее применении глобально (т.е. воздействуя на все пиксели

разом). Однако при использовании данного метода локально необходимо подбирать параметр γ для каждого анализируемого фрагмента.

Разработанный метод подразумевает, что модель машинного обучения автоматически должна подбирать параметр γ , основываясь на статистических параметрах фрагментов снимка. Помимо стандартных показатели, таких как максимальная, минимальная и средняя интенсивность пикселей, использовались четыре вида контрастов:

- Контраст Михельсона, оценивающий разницу между максимальной и минимальной яркостью.
- Среднеквадратический контраст, являющийся стандартным отклонением яркости пикселей.
- Глобальный контраст, измеряющий размах яркости.
- Контраст Харалика, анализирующий текстуру через матрицу совместной встречаемости пикселей [2].

Обработка данных и обучение

В качестве тренировочных и тестовых данных использовался набор снимков, подготовленный для конкурса «Night Photography Rendering Challenge 2025». Он содержит две группы снимков: необработанные, имеющие широкий динамический диапазон, и эталонные, обладающие нужным распределением яркости. Все снимки сделаны в ночное время суток в условиях недостаточной освещенности.

Для увеличения количества обучающей выборки исходные файлы подвергались аугментации. При подготовке данных анализировались не весь снимок целиком, а только его фрагмент 128 x 128.

Для ночных снимков характерно наличие искусственных источников света. Как правило, они не занимают подавляющую часть композиции, из-за чего при рандомизации процесса обрезки они часто отсутствуют в заготовочных фрагментах. Это, в свою очередь, приводит к обеднению данных ввиду большого количества именно темных областей в качестве обучающей выборки. Подобное может привести к переобучению с риском того, что модель будет пытаться уменьшить параметр γ (увеличить интенсивность пикселей) даже для областей с изначально высокой яркостью.

Чтобы увеличить разнообразие данных, помимо фрагментов с исходными интенсивностями пикселей, формировались также те, которые подвергались дополнительной аугментации путем случайного увеличения среднего уровня яркости. Для полученных фрагментов подсчитывались необходимые статистические параметры, которые подаются на вход модели.

Целевой переменной обучаемой модели является наилучший показатель γ для локальной области. Для его определения производилась гамма-коррекция фрагмента с перебором параметра в пределах от 0.01 до 10.

Для оценки каждого результата рассматривались две эталонные метрики: peak signal-to-noise ratio (PSNR) и structural similarity index measure (SSIM) [3]. PSNR показывает, насколько сильно искажено изображение по сравнению с оригиналом, измеряя разницу в интенсивности пикселей. SSIM оценивает структурное сходство между изображениями. Данная метрика гораздо более коррелирует с субъективной оценкой, и является более предпочтительной, но при этом она гораздо сложнее в вычислении. Тем самым было решено использовать PSNR в рамках разметки данных, а к SSIM обращаться на этапе тестирования. Таким образом, в качестве целевой переменной γ принимался тот показатель, при котором исходный фрагмент после гамма-коррекции давал наибольшее значение метрики PSNR.

Для обучения использовались регрессионные модели машинного обучения: полином, многослойный персептрон и ансамбль деревьев, обучающийся методом градиентного

бустинга. Предпочтительным вариантом при этом является полиномиальная модель, т.к. имеет наиболее простое устройство, что позволяет ей быстрее выдавать результат. Однако в случае низких показателей на этапе тестирования, данное преимущество будет нивелировано.

Оценка результатов работы

Помимо описанных выше двух метрик, используется вспомогательная метрика энтропии гистограммы [4], которая не требует сравнения с эталоном и высчитывается по формуле:

$$Entropy = - \sum_{i=0}^{255} l_i \log_2(l_i),$$

где l_i – доля пикселей с i -м уровнем яркости. Чем выше метрика, тем шире распределение яркостей, увеличивая восприятие деталей на их фоне.

Оценка результатов проводилась на 50 снимках разрешением 2000 x 2000. Обученные модели сравнивались не только между собой, но и с другими классическими методами по выравниванию яркости:

- Single-Scale Retinex (SSR), улучшающий детализацию, разделяя освещение и отражение через гауссово размытие [5].
- Contrast Limited Adaptive Histogram Equalization (CLAHE), локально усиливающий контраст с помощью выравнивания гистограммы, ограничивая при этом шум [6].
- Автоконтраст, который представляет собой обыкновенную нормализацию интенсивности пикселей.

В таблице 1 приведены результаты работы классических методов и обученных моделей.

Таблица 1. Метрики качества тестовой выборке

	Автоконтраст	SSR	CLAHE	Персептрон	Ансамбль	Полином
PSNR	11,347	17,069	15,670	17,546	17,465	17,047
SSIM	0,530	0,628	0,523	0,671	0,657	0,658
Entropy	7,459	7,077	5,907	6,299	6,223	6,299

На рисунке 1 продемонстрированы примеры обработок снимков классическими методами и обученными моделями.




Рис. 1. Пример результатов обработки:
а – эталонный снимок, б – автоконтраст, в – SSR, г – CLAHE,
д – персептрон, е – ансамбль, ж – полином

Как видно из таблицы автоконтраст и SSR сильно выигрывают по показателю энтропии, что также прослеживается на примерах из рисунка 1. При этом обученные модели показывают высокие значения для эталонных метрик. Таким образом, при использовании автоконтраста или SSR повышается как видимость деталей, так и риск увеличения шумов и появления артефактов.

Заключение

В результате проведенных исследований был проанализирован подход к восстановлению яркостных характеристик ночных снимков. Использование полносвязного персептрона с несколькими слоями показал наилучший результат по метрикам PSNR и SSIM, продемонстрировав тем самым перспективность подхода использования моделей машинного обучения для улучшения адаптивности некоторых классических методов изменения яркости и контраста. При выполнении задачи, модель сохраняет информацию на светлых участках и увеличивает распознаваемость деталей на темных.

Гибридизация машинного обучения и стандартных методов обработки устраняет недостаток в виде необходимости индивидуального подбора параметров вручную, сохраняя при этом все достоинства модифицируемого метода.

Список использованных источников

1. Understanding Lux and Illuminance // Test and Measurement World [Электронный ресурс]. – URL: test-and-measurement-world.com/terminology/general/understanding-lux-and-illuminance (дата обращения: 25.03.2025).
2. Haralick, R.M., Shanmugam, K., Dinstein, I. Textural Features for Image Classification // IEEE Transactions on Systems, Man, and Cybernetics. – 1973. – Vol. SMC-3(6). – P. 610-621.
3. 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.
4. Agaian S.S., Panetta K., Grigoryan A.M. Adaptive Image Enhancement Based on Histogram Entropy Optimization // IEEE Transactions on Image Processing. – 2001. – Vol. 10, no. 7. – P. 1041-1052
5. Parthasarathy S., Sankaran P. An automated multi-Scale Retinex with Color Restoration for image enhancement // ResearchGate. – 2012. – URL: researchgate.net/publication/254024214_An_automated_multi_Scale_Retinex_with_Color_Restoration_for_image_enhancement (дата обращения 04.12.2024)
6. Кокошкин А.В., Коротков В.А., Новичихин Е.П. Модификация метода CLAHE для компенсации влияния гидрометеоров // Текст: электронный // Журнал Радиоэлектроники. – 2017. – 10. [Электронный ресурс]. – URL: jre.cplire.ru/jre/oct17/10/text.pdf (дата обращения: 16.02.2025).