

МЕТОД ПРИВЕДЕНИЯ ОЦЕНОК JND В ОДНОРОДНОЕ ПРОСТРАНСТВО

Костычев Александр Михайлович

Студент

Факультет ВМК МГУ имени М. В. Ломоносова, Москва, Россия

E-mail: alexandr.kostychev@graphics.cs.msu.ru

Научный руководитель — Ватолин Дмитрий Сергеевич

Термин «Just Noticeable Difference» (JND) применяется при анализе пар изображений или видео для определения процента зрителей, которые не заметят разницы между двумя элементами. Этот термин широко используется в контексте сжатия данных. В данном случае, термин JND точки применяется для определения уровня сжатия, при котором определённый процент зрителей обнаружит различия между оригинальным и сжатым изображениями. JND может применяться в задаче оценки качества изображений и видео. Однако для этого необходимо иметь достаточное количество хорошо размеченных данных.

На сегодняшний день существует несколько наборов данных JND: MCL-JCI [1], SIAT-JSSI [2], VVC Dataset [3], KonJND-1k [4]. Однако все они были собраны в различных условиях просмотра контента: разное освещение, испытуемые, мониторы и расстояния до них и др. И точки JND, в таких различных условиях могут восприниматься по-разному. Поэтому при обучении или тестировании каких-либо методов на этих данных могут возникать некорректные результаты. Для возможности применения JND-методов на этих данных необходимо привести их в однородное пространство оценок.

Мы разметили набор данных MCL-JCI [1] при помощи краудсорс-сервиса разметки данных Subjectify.us. После этого мы обучили несколько регрессионных моделей машинного обучения, которые переводят исходные точки JND в оценки, полученные нами. В качестве признаков мы пробовали различные комбинации и вариации яркостных и цветовых компонент изображений:

- Среднее значение и энтропия на всём изображении;
- Среднее значение и энтропия в левом/правом верхнем/нижнем квадранте изображения;
- Среднее значение и энтропия в центральном квадранте изображения;

- Среднее значение и энтропия в областях изображения, которые сильнее всего искажаются при сжатии на основе метрик PSNR и SSIM.

В Таблице 1 приведены лучшие среди различных комбинаций признаков изображений результаты моделей. Модели RandomForestRegressor, LogisticRegression и KNeighborsRegressor показывают себя очень хорошо, а модель SVR хуже.

Модель	Ошибка (MAE)
RandomForestRegressor	0.76
LogisticRegression	1.8
KNeighborsRegressor	1.88
SVR	3.53

Таблица 1: Лучшие результаты моделей

Учитывая, что оценки находятся в интервале $[1, 100]$, а среднее стандартное отклонение исходных оценок наборов данных примерно равно 10, наши исследования показали, что можно создать метод, который с хорошей точностью будет переводить оценки, полученные в различных условиях, в пространство оценок, полученных методом краудсорса.

Литература

1. Lina J. Statistical study on perceived JPEG image quality via MCL-JCI dataset construction and analysis // In IS&T/SPIE Electronic Imaging. International Society for Optics and Photonics, 2016.
2. Fan C. Picture-level just noticeable difference for symmetrically and asymmetrically compressed stereoscopic images: subjective quality assessment study and datasets // In Journal of Visual Communication and Image Representation, 2019, No. 62. P. 140–151.
3. Xuelin S. Just noticeable distortion profile inference: a patch-level structural visibility learning approach // In IEEE Transactions on Image Processing 30, 2021, P. 26–38.
4. H. Lin Large-scale crowdsourced subjective assessment of picturewise just noticeable difference // In IEEE Transactions on Circuits and Systems for Video Technology, 2022, Vol. 32, No. 9, P. 5859–5873.