

# Статистическое представление изображений выборками случайных отсчетов фиксированного размера

В.Е. Анциперов<sup>1</sup>

<sup>1</sup>Институт радиотехники и электроники им. В.А. Котельникова РАН, Моховая 11/7, Москва, Россия, 125009

## Аннотация

В работе обосновывается способ представления изображений выборками случайных фотоотсчетов и приводится статистическое описание подобных представлений. Предлагаемый способ опирается на вытекающую из фундаментальных фактов теории взаимодействия излучения с веществом концепцию идеального изображения. С целью сокращения размеров представления идеальное изображение редуцировано к выборкам отсчетов фиксированного (контролируемого) размера. Показано, что статистическое распределение последних факторизуется в произведение распределений отдельных отсчетов, аналогично модели наивного байесова подхода, это позволяет использовать для работы с предложенными представлениями богатый арсенал средств машинного (байесова) обучения.

## Ключевые слова

вариационные автокодировщики, выборки случайных отсчетов, машинное обучение

## 1. Введение

Работа посвящена обоснованию и обсуждению одного способа представления данных для анализа широкого класса изображений. Предлагаемый способ ориентирован на обработку (распознавание, выделение характеристик, детектирование особенностей и т.д.) изображений с помощью вариационных автокодировщиков (VAE – variational autoencoders [1]).

Автокодировщики – это простые самообучаемые схемы, предназначенные для преобразования входных данных в подобные же им выходные с минимально возможным искажением, но с возможно большим сжатием промежуточного представления. Впервые автокодировщики появились в 1980-х годах, однако, относительно недавно вновь привлекли к себе внимание в связи с системами «глубокой архитектуры», где они самостоятельно (unsupervised) обучаются снизу вверх, после чего следует фаза контролируемого (supervised) обучения для верхнего уровня и точной настройки всей архитектуры.

Значительного улучшения характеристик автокодировщиков удалось достигнуть в последнее время в рамках модели вариационных автокодировщиков (VAE) [1]. Согласно байесовскому подходу, VAE относятся к классу порождающих (generative) моделей, которые рассматривают входные данные как случайные, порожденные некоторым вероятностным распределением. Как правило, порождающее распределение задается (с точностью до некоторых неизвестных параметров  $\theta$ ) посредством совместного распределения  $p_\theta(X, Z)$ , где  $X$  обозначает набор входных (наблюдаемых) данных, а  $Z$  – множество скрытых (ненаблюдаемых) переменных. Действительно, если для  $Z$  имеется некоторая оценка  $\hat{Z}$ , то новые данные  $Y = X$ , рассматриваемые как данные на выходе автокодировщика, порождаются (генерируются) с помощью распределения  $p_\theta(Y|\hat{Z}) = p_\theta(Y, \hat{Z})/p_\theta(\hat{Z})$ . Данная операция, называемая в контексте VAE декодированием, помимо оценок  $\hat{Z}$  требует также задания значений параметров  $\theta$ . Принципиально, эти величины могут быть найдены по входным данным  $X$  на предшествующем этапе кодирования по (апостериорным) распределениям  $p_\theta(Z|X) = p_\theta(X, Z)/p_\theta(X)$ , например, по схеме EM-алгоритма. Однако, ввиду того, что зависимость

$p_\theta(Z|X)$  от  $\theta$  и  $Z$  часто оказывается очень сложной, для VAE кодирования обычно, по аналогии с вариационным байесовым подходом (variational Bayesian inference), используется приближенное апостериорное распределение  $q_\phi(Z|X)$  из более простого параметрического семейства (детали см. в [1]).

## 2. Представление изображений выборками случайных отсчетов

Как следует из вышеизложенного, задание модели кодирования (encoder model)  $q_\phi(Z|X)$  является для VAE принципиальным моментом, поскольку именно она в первую очередь определяет как характеристики автокодировщика, так и эффективность его реализации. При этом, очевидно, выбор апостериорного распределений  $q_\phi(Z|X)$  существенно зависит, помимо прочего, от вида представления  $X$  входных данных для соответствующей предметной области.

В течение последнего времени нами была проведена определенная работа по поиску подходящих представлений для изображений – вначале для слабоинтенсивных, а затем и для более широкого класса [2]. Мы исходили из концепции идеального изображения как совокупности фотоотсчетов  $X = \{\vec{x}_i\}$  – физического результата регистрации потока квантов, падающих на чувствительную поверхность идеального устройства визуализации. Последнее представляет собой массив (матрицу) идеальных точечных детекторов, прототипами его являются сетчатка глаза животных и человека, фотопластинки с покрытием, содержащим светочувствительные зерна кристаллов галогенида серебра, светочувствительные КМОП-матрицы однофотонных фотодиодов.

Известно (см. обсуждение и дальнейшие ссылки в [2]), что представление изображений отсчётами статистически описывается как распределение вероятностей  $n$  точек  $\{\vec{x}_i\}$  некоторого двумерного неоднородного точечного пуассоновского процесса с функцией интенсивности пропорциональной интенсивности падающего излучения. Однако, в отличие от случая слабых интенсивностей, в случае классических изображений  $n \rightarrow \infty$  ( $10^8$  и более), в результате чего работа непосредственно с представлением  $X = \{\vec{x}_i\}$  представляется мало реалистичной.

Предложенное нами решение проблемы представления изображений аналогично упомянутому пуассоновскому, но изначально задается фиксированным размером  $k \ll \bar{n}$ . Именно, рассматривая представление идеального изображения  $X = \{\vec{x}_i\}$  как генеральную совокупность случайных точек и осуществляя из нее случайную выборку в  $k$  отсчетов  $X_k = \{\vec{x}_j\}$ , мы объявляем ее представлением изображения. Нами показано, что в тех же предположениях, что использованы при выводе статистики пуассоновского представления, статистика выборок фиксированного (не случайного) размера  $k$  задается плотностями распределений вида:

$$\rho(\vec{x}_1, \dots, \vec{x}_k) = \prod_{j=1}^k v(\vec{x}_j), \quad v(\vec{x}) = I(\vec{x}) / \int_{\Omega} I(\vec{x}) d\vec{x},$$

где  $I(\vec{x})$  – интенсивность излучения, падающего на чувствительную поверхность  $\Omega$  устройства.

Отметим, что концепция идеального изображения понадобилась нам только для обоснования статистического описания  $\rho(X_k)$  представления. Практическая же реализация представления  $X_k = \{\vec{x}_j\}$ ,  $\vec{x}_j \in \Omega$ , состоит в формировании  $k$  независимых, одинаково распределенных (iid) случайных отсчетов  $\vec{x}_j$ , связанных с нормированной интенсивностью  $v(\vec{x})$ . В случае, когда выборка формируется в процессе регистрации излучения, отсчеты отбираются из потока фотоэлектронов по мере их эмиссии, пока их число не достигнет величины  $k$ . Если же изображение уже задано в виде набора пикселей, по ним можно восстановить (reconstruct) приближенные значения  $I(\vec{x})$  в точках  $\Omega$ . Нормируя это приближение, можно получить аппроксимацию плотности распределения  $v(\vec{x})$ , после чего остается произвести  $k$  раз процедуру семплирования. Отметим в этой связи, что в области машинного обучения имеется богатый арсенал методов сэмпирования, объединенный общим названием методов Монте-Карло.

### 3. Литература

- [1] Kingma, D.P. An Introduction to Variational Autoencoders / D.P. Kingma, M. Welling // Foundations and Trends in Machine Learning – 2019. – Vol. 12(4). – P. 307-392. DOI: 10.1561/22000000056.
- [2] Antsiperov, V. Maximum Similarity Method for Image Mining / V. Antsiperov // Pattern Recognition. ICPR International Workshops and Challenges. Lecture Notes in Computer Science. – 2021. – Vol. 12665. – P. 301-313.