

Д.В. Сальников, О.Г. Васильченко

Национальный технический университет «Харьковский политехнический институт»,
г.Харьков, Украина

ПРИМЕНЕНИЯ НЕЙРОСЕТЕЙ С RESIDUAL АРХИТЕКТУРОЙ ДЛЯ ФИЛЬТРАЦИИ ИМПУЛЬСНЫХ ШУМОВ ИЗОБРАЖЕНИЙ

Аннотация: Нейросети представляют собой цепочки слоев над данными. В ходе процесса обучения каждый слой из цепочки «подбирает» необходимые коэффициенты для достижения необходимого результата. Метод обучения называют методом обратного распространения ошибки. На текущий момент обработка изображений – одна из наиболее быстро развивающихся областей обработки данных. Данные изображений подвергаются воздействию шумов на протяжении процедуры захвата и передачи данных по каналам связи. К сигналу применяется наиболее подходящий метод из имеющихся. Такой подход позволяет существенно повысить качество работы фильтра, но требует дополнительных вычислений для проведения детектирования и выбора фильтра. С каждым годом объем данных изображений увеличивается. Таким образом задача удаления шумов с изображений становится все более актуальной. В последнее время набирают популярность нейросетевые подходы к решению задачи фильтрации шумов. Для обучения сложных архитектур нейросетей используют дополнительные блоки, существенно влияющие на показатели производительности. В данной работе предложена архитектура нейросети с residual блоками, позволяющая осуществить фильтрацию с высокими показателями качества и времени.

Ключевые слова: фильтрация, шум, нейросеть, residual.

Для борьбы с воздействием шумов на изображения разработаны модифицированные медианные фильтры [0, 1, 2], большинство из которых успешно работают только в определенных условиях (при заданном уровне плотности шума и/или определенном типе шумового воздействия). Для борьбы с данными недостатками были созданы фильтры адаптивные фильтры, а также фильтры [3-7] комбинирующие несколько методов борьбы с разными видами шума, имеющие возможность детектировать вид зашумляющего воздействия. Таким образом к сигналу применяется наиболее подходящий метод из имеющихся. Такой подход позволяет существенно повысить качество работы фильтра, но требует дополнительных вычислений для проведения детектирования и выбора фильтра. Существенным недостатком также можно считать нелинейность операций детектирования, что практически сводит на нет возможность оптимизации алгоритма для работы на ПЛИС или векторных процессорах.

В последнее время набирают популярность методы фильтрации помех основанные на механизмах нейросетей [8, 9]. Данные методы позволяют подобрать коэффициенты, при которых фильтрация будет осуществлена с высоким качеством для различных типов зашумления и условий съемки. Кроме того, алгоритмы нейросетевой обработки изображений редко включают сложные с точки зрения оптимизации операции, что существенно повышает их привлекательность.

Проблема затухания градиента в сложных сетях

Нейросети представляют собой цепочки слоев (операций) над данными. В ходе процесса обучения каждый слой из цепочки «подбирает» необходимые коэффициенты для достижения необходимого результата. Метод обучения называют методом обратного распространения ошибки.

Не трудно прийти к выводу, что чем больше слоев в нейросети, тем большего качества предсказания выходных данных она позволяет добиться. К сожалению, имеет место так называемый эффект размывания градиента. В ходе обучения глубокой нейросети градиент «растворяется», что приводит к невозможности её обучить.

Для борьбы с таким эффектом применяют слой Batch Normalization [10]:

$$\mu_b = \frac{1}{m} \sum_{i=1}^m x_i, \quad (1)$$

$$\sigma_b^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_b)^2, \quad (2)$$

$$\hat{x}_i = \frac{x_i - \mu_b}{\sqrt{\sigma_b^2 + \xi}}, \quad (3)$$

$$\hat{y}_i = \gamma \hat{x} + \beta, \quad (4)$$

Позже были предложены также Layer Normalization, а также Instance Normalization.

Не смотря на положительный эффект, который оказывает нормализация на процесс обучения нейросети, существенным недостатком является наличие дополнительных вычислений как в процессе обучения, так и в процессе работы (inference'a сети).

Следует также отметить, что нормализация – сложная по своей природе операция в терминах делимости на несколько вычислительных устройств. Классически она может быть разделена только в одной из четырех размерностей входных данных. Что не является эффективным при вычислениях на современных GPU и CPU.

В последнее время распространение получают нейронные сети с *Residual* архитектурой [11], позволяющие обеспечить прохождение градиента в глубоких сетях без использования тяжеловесных с точки зрения вычисления слоев нормализации (рис. 1).




Рисунок 1 – Структура блоков с Residual архитектурой

Residual блоки являются своего рода байпасированием. Выход такого блока вычисляется как сумма/разность входа и выхода данного блока. В общем случае данный прием можно представить в виде математического уравнения:

$$y_i = add(x_i, f(x_i)), \quad (5)$$

где x_i – вход нейросетевого слоя,

y_i – выход этого слоя.

В данной статье предложен метод использования таких сетей для осуществления фильтрации импульсных шумов монохромных изображений.

Структура DnCNN

DnCNN представляет собой свёрточную нейросеть, состоящую из блоков с типовой архитектурой представленный на рисунке ниже. Каждый блок состоит из операции свертки, нормализации и активации (рис. 2).




Рисунок 2 – Структура сети DnCNN

Свёрточные нейросети показали свою эффективность в задачах классификации, сегментации и поиска объектов на изображении в качестве механизма выделения характерных черт объекта. Благодаря операции свертки с ядром они позволяют существенно снизить количество обучаемых параметров и в тоже время добиться высокого качества работы.

Структура DnCNN включает слои нормализации Batch Normalization в каждом из блоков. Поскольку этот слой фактически невозможно разбить для обработки на нескольких

вычислительных устройствах, это существенно сказывается на общей производительности алгоритма.

Другим немаловажным аспектом является этап обучения нейросети. На этом этапе нормализация также не является плюсом.

Общеизвестно, что невозможно обучить глубокие нейросети из-за явления затухания градиента. Блоки нормализации в топологии данной сети являются механизмом обеспечения обучаемости, т.е. поддержания значений градиента на нужном уровне.

Исследование DnCNN с применением Residual архитектуры

Для проверки гипотезы об эффективности применения Residual блоков в сверточной нейросети для удаления шума с изображения, были проведены исследования модифицированной DnCNN архитектуры с использованием *Residual блоков* – R-DnCNN (рис. 3). Для сравнения результаты работы представлены для сети с 5, 10 и 15 Residual блоками, а также оригинальной DnCNN.

Таким образом, в ходе проверки были рассмотрены различные конфигурации сети:

- R-DnCNN-5
- R-DnCNN-10
- R-DnCNN-15
- DnCNN




Рисунок 3 – Структура нейросети R-DnCNN

Для обучения использовался набор из 100 изображений зашумленных импульсным шумом с плотностью 25%.

Оценке подвергались качество удаления шума (использовались метрики PSNR и SSIM), а также скорость обучения нейросети (табл. 1, 2, рис. 4).

Обучение проводилось без использования GPU, на CPU Intel Core i5.

Таблица 1 – Скорость обучения нейросети


Архитектура	Время обучения одной эпохи, с	Время одного шага
DnCNN		
R-DnCNN 5	4578	2
R-DnCNN 10	8472	5
R-DnCNN 15	12367	7

Таблица 2 – Результаты работы R-DnCNN

Архитектура	PSNR	SSIM
DnCNN	33.39084211	0.9643057
R-DnCNN 5	35.4369947	0.989852675
R-DnCNN 10	36.02321303	0.980563554
R-DnCNN 15	36.24062496	0.982867092

Заключение

В ходе работы были представлены архитектуры нейросетей для фильтрации импульсных шумов с Residual блоками. Описанные сети показали высокие результаты качества фильтрации, сниженные показатели времени обучения, а также не имеющие в составе слоев нормализации, что положительно сказывается на возможности распараллеливания алгоритма на несколько вычислительных устройств.



а) зашумленное изображение, б) изображение после фильтрации R-DnCNN (5 слоев),
в) изображение после фильтрации R-DnCNN (15 слоев), г) изображение после фильтрации DnCNN

Рисунок 4 – Примеры работы нейросети

Литература

1. D. Brownrigg, "The weighted median filter," Commun. Assoc. Comput. Mach., vol. 27, pp. 807-818, Mar. 1984.
2. S.J. Ko and Y.H. Lee, "Center weighted median filters and their applications to image enhancement," IEEE Trans. Circuits Syst., vol. 38, pp. 984-993, 1991.
3. Bellanger M.G. Adaptive digital filters. 2nd ed. Marcel Dekker, 2001.
4. Haykin S. Adaptive filter theory. 4th ed. Prentice Hall, 2001.
5. Sayed A.H. Fundamentals of adaptive filtering. John Wiley and Sons, 2003.
6. Adaptive signal processing: applications to real-world problems. J. Benesty, Y. Huang, Eds. Springer, 2003.
7. Poularikas A.D., Ramadan Z.M. Adaptive filtering premier with MATLAB. CRC Press, 2006.
8. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising Kai Zhang, Wangmeng Zuo, Senior Member, IEEE, Yunjin Chen, Deyu Meng, Member, IEEE, and Lei Zhang Senior Member, IEEE.
9. Harold C. Burger, Christian J. Schuler, «Image denoising: Can plain Neural Networks compete with BM3D», IEEE International Conference on Computer Vision and Pattern Recognition 2012.
10. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift Sergey Ioffe, Christian Szegedy (Submitted on 11 Feb 2015 (v1), last revised 2 Mar 2015 (this version, v3)).
11. K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in IEEE Conference on Computer Vision and Pattern Recognition, 2016, pp. 770-778.

APPLICATIONS OF NEURAL NETWORKS WITH RESIDUAL ARCHITECTURE FOR FILTRATION OF IMPULSE NOISE ON IMAGES

D. Salnikov, O. Vasylenkov

Currently, image processing is one of the fastest growing data processing area. Image data becomes corrupted by noise during the capture and transmission of data over communication channels. Every year data size of the images grows up. Thus, removing noise from images is increasingly relevant task. Recently, neural network approaches of solving this problem become more popular. Additional blocks are used for training deep neural networks, that significantly affects the performance. This paper proposes a neural network architecture with residual blocks that allows filtering with high quality and performance.

Key words: denoising, noise, neural network, residual.