

УДК 621.397

ФИЛЬТРАЦИЯ ЦИФРОВЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ АВТОЭНКODЕРА

Ипатов А.А., аспирант кафедры динамики электронных систем Ярославского государственного университета им. П. Г. Демидова, e-mail: artoymirator@gmail.com;

Волохов В.А., к.т.н., доцент кафедры динамики электронных систем Ярославского государственного университета им. П. Г. Демидова, e-mail: volokhov@piclab.ru;

Приоров А.Л., д.т.н., доцент кафедры динамики электронных систем Ярославского государственного университета им. П. Г. Демидова, e-mail: andcat@yandex.ru;

Апальков И.В., к.т.н., доцент кафедры динамики электронных систем Ярославского государственного университета им. П. Г. Демидова, e-mail: ilya@apalkoff.ru.

FILTRATION OF DIGITAL IMAGES BASED ON AUTOENCODER

Ipatov A.A., Volokhov V.A., Priorov A.L., Apalkov I.V.

This paper presents the implementation and study of noise reduction algorithm, based on autoencoder. Autoencoder is a kind of feedforward neural network, which is unsupervised learning algorithm. Standard dataset were used to test the proposed filtering algorithm. Additive white Gaussian noise is considered as a noise model. This paper presents the numerical and visual results, showing the main features of considered algorithm.

Key words: image filtering, machine learning, feedforward neural network, autoencoder.

Ключевые слова: фильтрация изображений, машинное обучение, нейронная сеть прямого распространения, автоэнкодер.

Введение

На сегодняшний день алгоритмы цифровой обработки изображений, а именно шумоподавления [1], широко применяются в области современной науки и техники и имеют множество практических приложений. Например, можно использовать алгоритмы шумоподавления в качестве этапа предобработки цифровых изображений в системах технического зрения или для обработки медицинских снимков, сделанных в разных диапазонах длин волн. Также для человека наиболее важной частью информации является ее визуальная составляющая, именно поэтому обработка цифровых изображений столь необходима на данный момент времени.

Подавление шума в основном используется с целью улучшения визуального восприятия, то есть предназначено для приближения «искаженного» изображения к «идеальному». В частности, изображения, полученные в неблагоприятных условиях съемки, подвергаются воздействию различных шумов, которые создают электроникой устройств (полупроводниковые сенсоры) фотоаппарата. Вследствие чего, для получения высококачественных изображений необходимо разрабатывать подходы, позволяющие подавлять эти шумы.

Стоит отметить, что алгоритмы фильтрации обычно разрабатываются для подавления какого-то конкретного шума, так как на данный момент не существует универсальных фильтров, способных детектировать и подавлять все возможные виды шумов. Однако многие шумы можно довольно хорошо аппроксимировать моделью аддитивного белого гауссовского шума (АБГШ),

Представлены реализация и исследование алгоритма шумоподавления, построенного на основе автоэнкодера. Автоэнкодер является разновидностью нейронной сети прямого распространения, обучаемой без учителя. Для тестирования предложенного алгоритма фильтрации использовались стандартные базы тестовых изображений. В качестве модели шума рассматривался аддитивный белый гауссовский шум. Приведены численные и визуальные результаты, демонстрирующие основные особенности предложенного алгоритма.

что следует из центральной предельной теоремы, в которой говорится о том, что сумма из большого числа случайных величин, имеющих произвольное распределение, наилучшим образом описывается гауссовским распределением. Именно поэтому в настоящей работе при реализации и тестировании алгоритмов фильтрации использовалась модель АБГШ.

Достаточно интересным подходом к задаче фильтрации изображений является использование методов машинного обучения [2]. Машинное обучение – это обширная область науки и техники, подраздел искусственного интеллекта, использующий разделы математической статистики, теории вероятностей, численные методы оптимизации для извлечения полезной информации (знания) из данных. Методы машинного обучения используются для классификации, кластеризации, анализа больших баз данных и для других актуальных на сегодняшний день научно-технических задач. В работе предлагается реализация алгоритма фильтрации цифровых изображений, построенная на основе одного из методов машинного обучения – автоэнкодера.

Описание алгоритма фильтрации

Автоэнкодер (автоассоциатор) представляет собой специальную нейронную сеть прямого распространения

[2, 3], которая обучается без учителя, то есть, не используя размеченную базу данных. Это нейронная сеть подбирает значения выходов таким образом, чтобы они были как можно ближе к значениям на входе сети. На рис. 1 представлена модель трехслойного автоэнкодера (один входной слой, один скрытый и один выходной). Входной слой содержит шесть входных единиц (нейронов) и одну единицу смещения $x_0 = 1$; скрытый слой содержит три скрытые единицы и одну единицу смещения $a_0^{(2)} = 1$; выходной слой содержит такое же число единиц, что и входной.

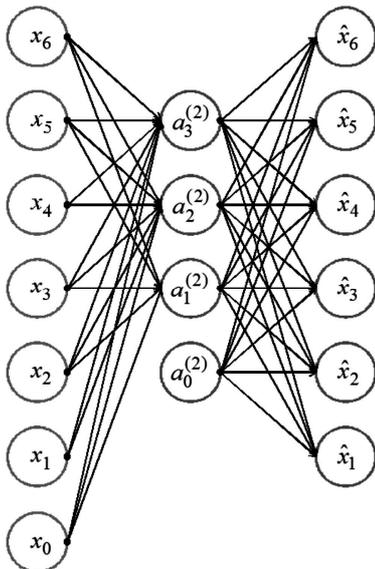


Рис. 1. Схема автоэнкодера, где $x_0 = 1$ и $a_0^{(2)} = 1$ – единицы смещения во входном и скрытом слоях.

Кружками обозначены нейроны в слоях, а стрелками показаны соединения между нейронами разных слоев

Автоэнкодер пытается получить функцию (гипотезу) $\mathbf{h}_{w,b}(\mathbf{x}) \approx \mathbf{x}$, которая аппроксимирует вход \mathbf{x} оценкой $\hat{\mathbf{x}}$ на выходе, как показано на рис. 1. Для того чтобы преобразование не было тривиальным, на скрытый слой автоэнкодера накладывают ограничение. Число единиц в скрытом слое должно быть меньше, чем во входном. Идентичное отображение $\hat{\mathbf{x}} = \mathbf{x}$ не позволяет получить «интересного» решения.

Ограничение числа нейронов в скрытом слое позволяет получить сжатое представление входных данных, в смысле понижения их размерности. Это означает, что автоэнкодер обучается восстанавливать входные данные из сжатого представления, что может быть полезно для реализации алгоритма шумоподавления.

Обучение такой нейронной сети выполняется с использованием метода обратного распространения ошибки путем минимизации стоимостной функции, например, с помощью градиентного спуска, позволяющего настроить веса (параметры модели) автоэнкодера и получить гипотезу $\mathbf{h}_{w,b}(\mathbf{x}) \approx \mathbf{x}$.

Рассмотрим алгоритм шумоподавления на основе модели трехслойного автоэнкодера, пример которого приведен выше. Схема предлагаемого алгоритма фильтрации изображения на основе автоэнкодера представлена на рис. 2.

На вход алгоритма поступает зашумленное АБГШ \mathbf{n}

с нулевым математическим ожиданием и известной дисперсией σ^2 изображение $\mathbf{y} = \mathbf{x} + \mathbf{n}$. Обозначим через $m(i)$ число единиц в конкретном слое автоэнкодера, где индекс $i = 1, 2, 3$ обозначает номер слоя сети.

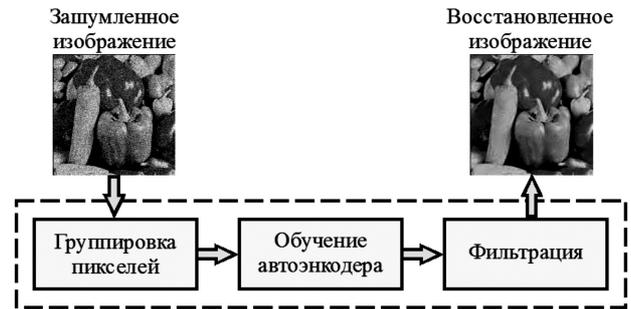


Рис. 2. Схема фильтрации изображения на основе автоэнкодера

Основные этапы работы предлагаемого алгоритма представлены ниже.

1. Выделяем на зашумленном изображении y совокупность перекрывающихся блоков, каждый из которых состоит из области обучения, области фильтрации и области наложения блоков [4, 5].

2. Для обучения автоэнкодера необходимы данные, взятые из зашумленного изображения, поэтому требуется сформировать матрицу данных S_y , столбцами которой являются всевозможные вектора обучения, набранные внутри области обучения. При формировании векторов обучения внутри области обучения выбираются всевозможные блоки размером $l \times l$, которые затем представляются в виде векторов столбцов размером l^2 . Матрица данных S_y имеет размер $l^2 \times n$, где l^2 – размер векторов обучения, то есть размерность данных, n – количество набранных векторов обучения.

3. Подготавливаем обрабатываемые данные, состоящие из яркостей пикселей изображения y , для обучения автоэнкодера, а именно, производим масштабирование данных в S_y путем деления их на максимальное значение яркости пикселя в зашумленном изображении. Полученную матрицу обозначим через \bar{S}_y .

4. Используем модель автоэнкодера, у которого число входных единиц $m^{(1)}$ в первом слое будет равно размеру вектора обучения l^2 , то есть число нейронов во входном слое зависит от размерности данных в матрице \bar{S}_y . Количество нейронов в скрытом слое должно быть меньше количества нейронов во входном слое ($m^{(1)} < m^{(2)}$). Это условие требуется для того, чтобы автоэнкодер сжал входные данные, отбросив связанные с шумом компоненты. Этим автоэнкодер очень похож на один из часто используемых методов сокращения размерности данных – анализ главных компонент [2].

5. Выполняем алгоритм прямого распространения сигнала, который в данном случае описывается следующими выражениями, представленными в матричной форме:

$$\mathbf{a}_j^{(2)} = f(\mathbf{z}_j^{(2)}) = f(\mathbf{W}^{(1)}(\bar{S}_y)_j + \mathbf{b}^{(1)}), \quad (1)$$

$$\mathbf{a}_j^{(3)} = \mathbf{h}_{w,b}((\bar{S}_y)_j) = \mathbf{z}_j^{(3)} = \mathbf{W}^{(2)}\mathbf{a}_j^{(2)} + \mathbf{b}^{(2)}. \quad (2)$$

Активации единиц скрытого слоя автоэнкодера получают при использовании нелинейного преобразования

f , основанного на сигмоидной функции [2], а активации нейронов на выходе сети – при помощи линейного преобразования, определяющего линейный декодер. В выражениях (1) и (2) $(\bar{S}_y)_j$ – j -й вектор-столбец матрицы \bar{S}_y , $\mathbf{a}_j^{(2)}$ – вектор-столбец размерностью $m^{(2)}$ рассчитанных активаций нейронов скрытого слоя автоэнкодера, $\mathbf{a}_j^{(3)}$ – вектор-столбец размерностью $m^{(1)}$ рассчитанных активаций нейронов выходного слоя, $\mathbf{W}^{(1)}$ – матрица размерностью $m^{(2)} \times m^{(1)}$, содержащая параметры модели и обеспечивающая связь между нейронами входного и скрытого слоев автоэнкодера, $\mathbf{W}^{(2)}$ – матрица размерностью $m^{(1)} \times m^{(2)}$, содержащая параметры модели и обеспечивающая связь между нейронами скрытого и выходного слоев автоэнкодера, $\mathbf{b}^{(1)}$ и $\mathbf{b}^{(2)}$ – вектора-столбцы размером $m^{(2)}$ и $m^{(1)}$, соответственно, содержащие элементы смещения для нейронов скрытого и выходного слоев.

Необходимо отметить, что исходно веса нейронной сети инициализируются случайным образом, для того чтобы избежать проблемы симметричности весов.

6. Получив начальную гипотезу $\mathbf{h}_{w,b}((\bar{S}_y)_j)$, определяем следующую стоимостную функцию, посчитанную по всей выборке векторов обучения в матрице \bar{S}_y :

$$J(\mathbf{W}, \mathbf{b}) = \left[\frac{1}{2n} \sum_{j=1}^n \|\mathbf{h}_{w,b}((\bar{S}_y)_j) - (\bar{S}_y)_j\|_2^2 \right] + \frac{\lambda}{2} \left[\sum_{j=1}^{m^{(2)}} \sum_{k=1}^{m^{(1)}} (W_{jk}^{(1)})^2 + \sum_{j=1}^{m^{(1)}} \sum_{k=1}^{m^{(2)}} (W_{jk}^{(2)})^2 + \sum_{j=1}^{m^{(2)}} (b_j^{(1)})^2 + \sum_{j=1}^{m^{(1)}} (b_j^{(2)})^2 \right], \quad (3)$$

где $\|\cdot\|_2$ – L^2 -норма, а λ – параметр регуляризации, контролирующей сложность модели.

7. Производим поиск частных производных функции (3) по параметрам $\mathbf{W}^{(1)}$, $\mathbf{W}^{(2)}$, $\mathbf{b}^{(1)}$, $\mathbf{b}^{(2)}$ с использованием алгоритма обратного распространения ошибки [2].

8. Получив необходимые частные производные

функции (3), осуществляем ее минимизацию по параметрам сети $\mathbf{W}^{(1)}$, $\mathbf{W}^{(2)}$, $\mathbf{b}^{(1)}$, $\mathbf{b}^{(2)}$ при помощи алгоритма численной оптимизации Бройдена–Флетчера–Гольдфарба–Шанно с ограниченным использованием памяти.

9. После минимизации стоимостной функции получаем параметры обученной сети $\mathbf{W}^{(1)}$, $\mathbf{W}^{(2)}$, $\mathbf{b}^{(1)}$, $\mathbf{b}^{(2)}$. Пропускаем через автоэнкодер зашумленные данные из матрицы \bar{S}_y , выполняя алгоритм прямого распространения (1) и (2) с использованием обновленных параметров сети. В итоге получаем оценку \hat{S}_x матрицы незашумленных данных S_x . Далее преобразовываем вектора обучения из столбцов матрицы \hat{S}_x обратно в блоки размерами $l \times l$, вкладывая их в соответствующие пространственные позиции области обучения. Область наложения блоков усредняется арифметически. Получаем восстановленную область обучения, внутри которой выделяем область фильтрации. Обучая автоэнкодер и обрабатывая им все оставшиеся области фильтрации на изображении \mathbf{y} , а затем, вкладывая их в соответствующие пространственные позиции, получим оценку \hat{x} неискаженного изображения x . Области фильтрации вкладываются с наложением, поэтому область наложения необходимо арифметически усреднить, чтобы устранить артефакты блочности.

Результаты моделирования

Рассматриваемый в работе алгоритм реализован в пакете прикладных программ Matlab. Для проведения исследований использовался «классический» набор тестовых полутоновых изображений размером 256×256 и 512×512 пикселей, предложенных для анализа на интернет-сайте [6]. В качестве численных метрик оценки качества в работе применялись пиковое отношение сигнала к шуму (ПОСШ, дБ) [7] и коэффициент структурного подобия (КСП) [8].

Численные и визуальные результаты восстановления изображений, зашумленных АБГШ, с использованием предложенного алгоритма шумоподавления на основе автоэнкодера приведены на рис. 3 и рис. 4.



а) исходное изображение
(∞ дБ; 1)



б) зашумленное изображение
(20,54 дБ; 0,350)



в) восстановленное изображение (27,80 дБ; 0,815)

Рис. 3. Результат восстановления тестового изображения «Фотограф» (256×256), искаженного АБГШ с $\sigma = 25$, с указанием ПОСШ, дБ и КСП



а) исходное изображение (+ дБ; 1)



б) зашумленное изображение
(20,24 дБ; 0,273)



в) восстановленное изображение
(31,37 дБ; 0,847)

Рис. 4. Результат восстановления тестового изображения «Лена» (512×512), искаженного АБГШ с $\sigma = 25$, с указанием ПОСШ, дБ и КСП



а) исходное изображение (∞ дБ; 1)



б) зашумленное изображение
(17,54 дБ; 0,300)



в) предложенный алгоритм
фильтрации (27,58 дБ; 0,808)



г) курвлет-преобразование [9]
(27,23 дБ; 0,789)



д) нелокальные средние [10]
(26,22 дБ; 0,734)



е) вейвлет-преобразование [11, 12]
(22,91 дБ; 0,608)

Рис. 5. Результаты восстановления фрагментов тестового изображения «Барбара II» (512×512), искаженного АБГШ ($\sigma = 35$), с указанием ПОСШ, дБ и КСП

Таблица 1. ПОСШ восстановленных изображений для $\sigma = 25$

Тестовое изображение	Предложенный алгоритм	Курвлет-преобразование	Нелокальные средние	Вейвлет-преобразование
«Фотограф»	27,80	27,36	28,05	24,41
«Лена»	31,37	30,72	30,21	27,84
«Лодки»	28,93	28,57	28,06	25,82
«Барбара II»	29,63	28,93	28,40	24,19

Таблица 2. КСП восстановленных изображений для $\sigma = 25$

Тестовое изображение	Предложенный алгоритм	Курвлет-преобразование	Нелокальные средние	Вейвлет-преобразование
«Фотограф»	0,815	0,767	0,795	0,696
«Лена»	0,847	0,823	0,797	0,753
«Лодки»	0,774	0,757	0,733	0,661
«Барбара II»	0,860	0,837	0,811	0,680

На рис. 5 представлены численные и визуальные результаты восстановления изображений, зашумленных АБГШ, с использованием предложенного алгоритма шумоподавления на основе автоэнкодера и ряда алгоритмов фильтрации, известных из научно-технической литературы [9-12].

Дополнительно в табл. 1 и табл. 2 представлены численные результаты сравнения предложенного алгоритма фильтрации с алгоритмами [9-12] по метрикам ПОСШ и КСП, соответственно. Среднеквадратическое отклонение $\sigma = 25$. В качестве тестовых изображений выбраны: «Фотограф» (256×256), «Лена» (512×512), «Лодки» (512×512) и «Барбара II» (512×512)

Анализ визуальных и численных результатов показывает, что для указанных тестовых изображений и степеней зашумления алгоритм фильтрации на основе автоэнкодера показывает наилучшие результаты по сравнению с рассматриваемыми подходами. Отметим, что предложенный алгоритм достаточно качественно восстанавливает высокотекстурированные области (рис. 5в). Однако для изображений, содержащих объекты с высококонтрастными изменениями яркости, при прохождении через их границу, предложенный алгоритм фильтрации приводит к появлению эффекта «ложного оконтуривания» (эффекта «звона») границ изображения (рис. 3в).

Заключение

В работе рассмотрено применение автоэнкодера в задаче фильтрации цифровых полутоновых изображений. Основным недостатком представленного алгоритма является высокая вычислительная сложность, обусловленная тем, что необходимо проводить обучение автоэнкодера для обработки каждой области фильтрации на зашумленном изображении. Ускорить работу алгоритма можно при помощи распараллеливания кода и его выполнения на графическом процессоре видеокарты. Дополнительно необходимо отметить то, что восстановленные алгоритмом изображения могут содержать артефакты в виде «звона границ». Основным достоинством алгоритма является возможность качест-

венного восстановления высокотекстурированных областей изображения из зашумленных данных.

Работа выполнена при поддержке РФФИ (проект № 15 08-99639-а).

Литература

1. Katkovnik V., Foi A., Egiazarian K., Astola J. From local kernel to nonlocal multiple-model image denoising // *Int. J. Computer Vision*. 2010. V. 86, № 8. P. 1–32.
2. Marsland S. *Machine learning: an algorithmic perspective*. Chapman and Hall, 2009.
3. Vincent P. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion // *J. Machine Learning Research*. 2010. V. 11. – P. 3371–3408.
4. Muresan D.D., Parks T.W. Adaptive principal components and image denoising // *Proc. IEEE Int. Conf. Image Processing*. 2003. V. 1. – P. 101–104.
5. Priorov A., Tumanov K., Volokhov V. Efficient denoising algorithms for intelligent recognition systems // In: Favorkaya M., Jain L.C. (eds.) *Computer Vision in Control Systems-2, Intelligent Systems Reference Library*, Springer International Publishing. 2015. V. 75. – P. 251–276.
6. The UGR-DECSAI-CVG image database, <http://decsai.ugr.es/cvg/dbimagenes>.
7. Сэломон Д. *Сжатие данных, изображений и звука*. – М.: Техносфера, 2004.
8. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image quality assessment: from error visibility to structural similarity // *IEEE Trans. Image Processing*. 2004. V. 13, № 4. – P. 600–612.
9. Starck J.-L., Candès E.J., Donoho D.L. The curvelet transform for image denoising // *IEEE Trans. Image Processing*. 2002. V. 11, № 6. P. 670–684.
10. Buades A., Coll B., Morel J.M. Nonlocal image and movie denoising // *Int. J. Computer Vision*. 2008. V. 76, № 2. – P. 123–139.
11. Malla S. *A wavelet tour of signal processing*. Academic Press, 1999.
12. Donoho D.L., Johnstone I.M., Keryacharian G., Picard D. Wavelet Shrinkage: Asymptopia? // *J.R. Statist. Soc. B*. 1995. V. 57, № 2. – P. 301–369.