

УДК 535.015 + 57.087.1 + 004.418
EDN: LYXXSN

PACS: 42.62.Be



Обработка оптоакустического сигнала для восстановления изображения на основе нейронных сетей

Д. А. Кравчук

Рассмотрены методы обработки акустического сигнала полученного при оптоакустическом эффекте в жидкости. Предложена 12-ти слойная сверточная нейронная сеть, обученная путем минимизации потерь среднего квадратного отклонения. Обработан экспериментально полученный акустический сигнал полученный при оптоакустическом эффекте. Рассмотрена схема решения обратной задачи оптоакустической реконструкцией изображений. Результаты исследования показывают, что нейронная сеть с глубоким обучением, с помощью обучения на основе самоконтроля, может достичь более высокой точности реконструкции с меньшими временными.

Ключевые слова: оптоакустический эффект, обработка сигнала, акустический сигнал, лазер.

DOI: 10.51368/1996-0948-2023-1-10-14

Введение

В последние годы глубокое обучение с использованием нейронных сетей стало привлекательной методологией анализа медицинских изображений благодаря своей эффективности [1]. С точки зрения восстановления изображений путем решения обратных задач успешно реализовано множество методов, основанных на глубоком обучении. Самый простой способ — обучить глубокую нейронную сеть непосредственному нелинейному преобразованию измерений (или низкокачественной реконструкции) в окончательное высококачественное реконструированное изображение [2, 3]. В качестве альтернативы методы глубокого обучения пытаются объединить традици-

онные методы, основанные на моделях, и метод глубокого обучения, управляемый данными, для достижения точной и эффективной реконструкции [4, 5]. В этих методах изображения высокого качества, полученные с помощью обычных методов необходимы в качестве обучающих меток, и их качество будет определять производительность обученной глубокой нейронной сети. Будем использовать подход с самостоятельным обучением, как показано на рис. 1. По сравнению с обычными методами на основе глубокого обучения, которые обычно используют схему обучения с учителем, для обучения не требуется достоверность объекта [6, 7]. Во множестве случаев было бы сложно или даже невозможно получить достоверные данные, такие как функция отражательной способности ткани при формировании ультразвукового луча.

При обучении с учителем, термин достоверности данных вычисляется на основе близости (L_2) между выходными данными и исходной истиной x (оба в области изображения). Поскольку истинное значение x трудно получить, близость между y и x эквивалентна близости между y и измерением $Hx = y$ без учета шума.

Кравчук Денис Александрович, к.т.н., доцент.
E-mail: kravchukda@sfn.edu.ru; denik545@ya.ru
ФГАОУ ВО «Южный федеральный университет»
ИНЭП.
Россия, 347922, г. Таганрог, ул. Шевченко, 2, корп. «Е».

Статья поступила в редакцию 17.10.2022

После доработки 4.11.2022

Принята к публикации 11.11.2022

© Кравчук Д. А., 2023

Материалы и методы

Решение обратной задачи сводится к получению информации о неизвестном интересующем объекте по его измерениям. Реконструкция медицинских изображений является одним из наиболее успешных ее применений, таких как компьютерная томография (КТ) [8], магнитно-резонансная томография (МРТ) [9], позитронно-эмиссионная томография (ПЭТ) [10] и ультразвуковая (УЗИ) визуализация [11]. Эти методы, основанные на обратных задачах, обычно начинаются с создания модели измерения $y = F(x)$, чтобы отразить взаимосвязь между объектом $x \in R^m$ и измерения $y \in R^n$. Если зависимость линейная, то смоделирован в виде: $y = Hx + b$ где $H \in R^{n \times m}$ – матрица измерений, b обозначает аддитивный шум.

Обратная задача обычно недоопределена (количество уравнений n меньше, чем количество неизвестных m), что приводит к множеству возможных решений. Даже если в случае, когда $n = m$, число обусловленности H^{-1} обычно очень велико, поэтому решение очень чувствительно к шуму сигнала. Чтобы получить уникальное и надежное решение обратной задачи, необходимо наложить регуляризацию, чтобы ввести априорные знания об объекте в процессе решения, такие как регуляризация [12], регуляризация Тихонова [13] и разреженная регуляризация на основе вейвлет анализа [14]. Наконец, обратная задача решается с использованием следующего алгоритма выпуклой оптимизации, показанного на рис. 1: $\min \|y - Hx\|_2 + \alpha \|R(x)\|_{l_1}$, где $\|\cdot\|_2$ обозначает норму L2, $\|\cdot\|_{l_1}$ обозначает норму L1 или L2, $R(\cdot)$ – оператор регуляризации и α соответствующий вес. Несмотря на то, что регуляризованные итеративные алгоритмы оптимизации обычно могут достигать приемлемых результатов, они не являются лучшим выбором для развертывания в реальных приложениях из-за их высокой вычислительной сложности (итеративный характер) и сложности выбора гиперпараметров. Матрица линейных измерений H устанавливается для отражения функций рассеяния точек системы на каждой сетке изображений. Выходная карта нейронной сети с глубоким обучением (многослой-

ная) восстанавливается в отфильтрованное изображение с использованием модели прямого измерения, а затем используется для вычисления среднеквадратичного отклонения для обучения нейросети.

Будем считать, что эхо-сигналы, принимаемые конкретным элементом преобразователя для аподизированной передачи плоской волны, представляют собой линейную комбинацию принятых эхо-сигналов этим элементом для всех датчиков с одинаковыми аподизациями [15]. Коэффициенты линейной комбинации представляют собой аподизацию передачи, используемую при передаче РВ. Таким образом, линейная модель измерения может быть установлена в виде $y = Hx$ для отражения взаимосвязи между полученными данными $x \in R^m$ и данными $y \in R^n$, где $H \in R^{n \times m}$ – матрица измерений, соответствующая применяемым аподизациям.

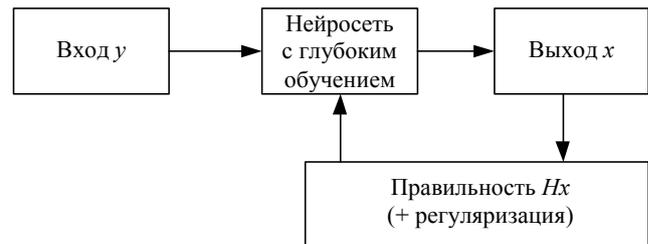


Рис. 1. Метод решения обратной задачи на основе нейронной сети

На рис. 1 приведена сверточная нейронная сеть, обученная путем минимизации потерь среднего квадратного отклонения, между полученными данными y и их восстановленной версией $y' = Hx$, для этого будем использовать регуляризацию разреженности данных, которые должны быть восстановлены в области вейвлета.

Время прохождения сигнала t может быть рассчитано как для эхо-сигналов, обратно рассеянных каждой сеткой формирования луча и принятых каждым элементом преобразователя. Время записи t_r также может быть рассчитано для каждого образца, записанного элементом преобразователя.

Матрица линейных измерений H устанавливается в соответствии с соотношением времени t , чтобы отразить соотношение между полученными данными y каждого канала и получаемыми данными x (без учета шума) $y = Hx$.

Предлагается использовать 12-слойную сверточную нейронную сеть, основанную на архитектуре автоэнкодера. Входными данными для сверточной нейронной сети является низкокачественное решение $x' = H_t$ обратной задачи (полученное с использованием обратной проекции), а не измерение.

Будем считать, что вейвлет-функция $\Psi(t)$ подчиняется следующим условиям:

$$\Psi(t) \in L^1(R, dt) \cap L^2(R, dt)$$

$$\Psi(\omega) \in L^1\left[R \setminus \{0\}, \frac{d\omega}{|\omega|}\right] \cap L^2\left[R \setminus \{0\}, \frac{d\omega}{|\omega|}\right]$$

где $L^1(R)$ и $L^2(R)$ обозначают две функции пространства; $\Psi(\omega)$ – преобразование Фурье вейвлет-функции $\Psi(t)$ и $\Psi(\omega) = 0$, когда $\omega < 0$ [16, 17].

При рассмотрении произвольной функции $f(t) = L^2(R, dt)$, ее вейвлет-преобразование

исходной вейвлет-функции $\Psi(t)$, определяется в виде [18]:

$$W_f(b, a) = \frac{1}{a} \int_{-\infty}^{\infty} f(t) \overline{\Psi\left[\frac{t-b}{a}\right]} dt.$$

Таким образом, проекции распределения оптического поглощения могут быть восстановлены с использованием алгоритма обратной фильтрации: [18, 19]

$$\iint_{|r|=ct} A(r) ds = \frac{4\pi C_p kt}{\beta r_p} IFFT\left(\frac{P_{dt}(\omega)W(\omega)}{P_{d0}(\omega)}\right)$$

где фильтр $W(\omega)$ является ключом к восстановлению оптоакустического изображения [17]. Таким образом, можно представить результаты обработки оптоакустического сигнала, полученного в жидкости рис. 2 слева [20] и результат обработки сигнала рис. 2 справа.

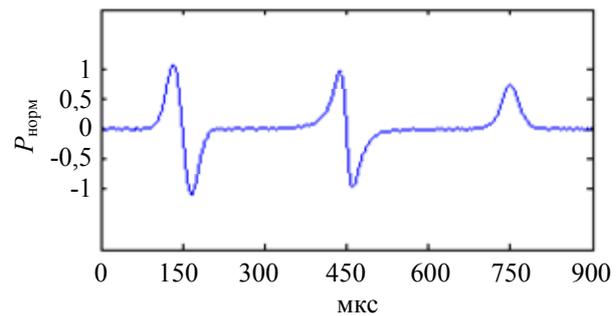
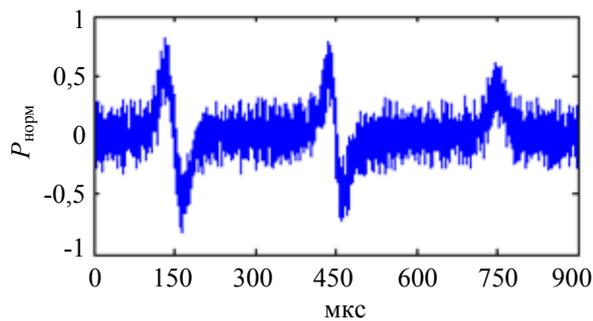


Рис. 2. Результаты обработки оптоакустического сигнала

Заключение

В работе предложена схема решения обратной задачи оптоакустической реконструкцией изображений. Результаты показывают, что нейронная сеть с глубоким обучением [7], с помощью обучения на основе самоконтроля, может достичь более высокой точности реконструкции с меньшими временными затратами на вычисления по сравнению с обычными методами.

При этом матрица измерений является связующим звеном между данными измерений и реконструируемыми сигналами, а также играет важную роль в вычислении потерь при обучении нейронной сети. При ультразвуковой и оптоакустической реконструкции изображений

входом нейронной сети является решение обратной задачи, полученное методом обратного проецирования. Выбор входных данных зависит от сложности модели измерения. Поскольку обратная задача, как правило, некорректна или не доопределена, регуляризация, основанная на априорном знании сигналов, подлежащих реконструкции, должна применяться как функция потерь во время обучения, чтобы повысить точность реконструкции.

ЛИТЕРАТУРА

1. Lijens G. et al. / Med. Image Anal. Elsevier. 2017. Vol. 42. P. 60–88.

2. Zhu B. et al. / Nature. 2018. Vol. 555. № 7697. P. 487–492.
3. Chen H. et al. / IEEE Trans Med Imaging. 2017. Vol. 36. № 12. P. 2524–2535.
4. Zhang H. et al. / Institute of Electrical and Electronics Engineers Inc. 2021. Vol. 40. № 2. P. 621–634.
5. Solomon O. et al. / IEEE Trans. Med. Imaging. 2020. Vol. 39. № 4. P. 1051–1063.
6. Кравчук Д. А., Старченко И. Б., Орда-Жигулина Д. В., Воронина К. А. / Акустический журнал. 2021. Т. 67. С. 345–348.
7. Кравчук Д. А. / Прикладная физика. 2021. № 2. С. 73–77.
8. Zhang Y., Yu H. / IEEE Trans. Med. Imaging. 2018. Vol. 37. № 6. P. 1370–1381.
9. Lustig M., Donoho D., Pauly J. M. / Magn. Reson. Med. 2007. Vol. 58. № 6. P. 1182–1195.
10. Häggström I. et al. / Med. Image Anal. 2019. Vol. 54. P. 253–262.
11. Besson A. et al. / IEEE Trans. Ultrason. Ferroelectr. Freq. Control. 2017. Vol. 65. № 3. P. 339–355.
12. Rudin L. I., Osher S., Fatemi E. / Phys. D Nonlinear Phenom. 1992. Vol. 60. № 1–4. P. 259–268.
13. Berthon B. / Phys. Med. Biol. 2018. Vol. 63. № 3. P. 03NT03.
14. Besson A. et al. / IEEE Trans. Ultrason. Ferroelectr. Freq. Control. 2016. Vol. 63. № 12. P. 2092–2106.
15. Liu J., He Q., Luo J. / IEEE Trans. Med. Imaging. 2017. Vol. 36. № 4. P. 878–891.
16. Орда-Жигулина Д. В., Орда-Жигулина М. В., Старченко И. Б., Кравчук Д. А. / Моделирование, оптимизация и информационные технологии. 2018. Т. 6. № 3. С. 30–39.
17. Кравчук Д. А. / Известия Юго-Западного государственного университета Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2019. Т. 9. № 1. С. 67–75.
18. Boukhamla A., Merouani H. F., Sissaoui H. / Evol. Syst. 2016. Vol. 7. № 3. P. 197–205.
19. Wang Y. et al. / Phys. Med. Biol. 2004. Vol. 49. № 14. P. 3117–3124.
20. Кравчук Д. А. / Прикладная физика. 2022. № 3. С. 63–66.

PACS: 42.62.Be

Optoacoustic signal processing for image restoration based on neural networks

D. A. Kravchuk

Southern Federal University
Bld. E, 2 Schevchenko st., Taganrog, 347922, Russia
E-mail: kravchukda@sfnedu.ru; denik545@ya.ru

Received 17.10.2022; revised 4.11.2022; accepted 11.11.2022

The paper considers methods for processing an acoustic signal obtained with an optoacoustic effect in a liquid. A 12-layer convolutional neural network is proposed, trained by minimizing the loss of the mean square deviation. The experimentally obtained acoustic signal obtained with the optoacoustic effect has been processed. A scheme for solving the inverse problem by optoacoustic image reconstruction is considered. The results of the study show that a deep learning neural network, with the help of self-supervision based learning, can achieve higher reconstruction accuracy with shorter time frames.

Keywords: optoacoustic effect, signal processing, acoustic signal, laser.

DOI: 10.51368/1996-0948-2023-1-10-14

REFERENCES

1. Litjens G. et al., Med. Image Anal. **42**, 60–88 (2017).
2. Zhu B. et al., Nature **555** (7697), 487–492 (2018).
3. Chen H. et al., IEEE Trans. Med. Imaging **36** (12), 2524–2535 (2017).

4. Zhang H. et al., Institute of Electrical and Electronics Engineers Inc. **40** (2), 621–634 (2021).
5. Solomon O. et al., IEEE Trans. Med. **39** (4), 1051–1063 (2020).
6. Kravchuk D. A., Voronina K. A., Starchenko I. B. and Orda-Zhigulina D. V., Acoustical physics **67**, 345–348 (2021).
7. Kravchuk D. A., Applied Physics, № 2, 73–77 (2021) [in Russian].
8. Zhang Y. and Yu H., IEEE Trans. Med. Imaging **37** (6), 1370–1381 (2018).
9. Lustig M., Donoho D. and Pauly J. M., Magn. Reson. Med. **58** (6), 1182–1195 (2007).
10. Häggström I. et al., Med. Image Anal. **54**, 253–262 (2019).
11. Besson A. et al., IEEE Trans. Ultrason. Ferroelectr. Freq. Control. **65** (3), 339–355 (2017).
12. Rudin L. I., Osher S. and Fatemi E., Phys. D Nonlinear Phenom. **60** (1–4), 259–268 (1992).
13. Berthon B., Phys. Med. Biol. **63** (3), 03NT03 (2018).
14. Besson A. et al., IEEE Trans. Ultrason. Ferroelectr. Freq. Control. **63** (12), 2092–2106 (2016).
15. Liu J., He Q. and Luo J., IEEE Trans. Med. **36** (4), 878–891 (2017).
16. Orda-Zhigulina D. V., Orda-Zhigulina M. V., Starchenko I. B. and Kravchuk D. A., The scientific journal modeling, optimization and information technology **6** (3), 30–39 (2018) [in Russian].
17. Kravchuk D. A., Series Control, computer engineering, information science. Medical instruments engineering **9** (1), 67–75 (2019).
18. Boukhamla A., Merouani H. F. and Sissaoui H., Evol. Syst. **7** (3), 197–205 (2016).
19. Wang Y. et al., Phys. Med. Biol. **49** (14), 3117–3124 (2004).
20. Kravchuk D. A., Applied Physics, № 3, 63–66 (2022) [in Russian].