

УДК 538.97

**Сверточные нейронные сети для реконструкции трехмерных моделей
нейтронной томографии из неполных данных****Б.А. Бакиров, В.С. Смирнова**Научный руководитель: д.т.н. С.Е. Кичанов
Объединенный институт ядерных исследований,
Россия, г. Дубна, ул. Жолио-Кюри, 6, 141980E-mail: bulatbakirov@jinr.ru**Convolutional neural networks for reconstruction of 3D neutron
tomography models from incomplete data****B.A. Bakirov, V.S. Smirnova**Scientific Supervisor: Dr. S.E. Kichanov
Joint Institute for Nuclear Research, Russia, Dubna, Joliot-Curie str., 6, 141980
E-mail: bulatbakirov@jinr.ru

Abstract. *In the present study, we developed a new algorithm for reconstructing three-dimensional neutron tomography models from an incomplete data set. Our proposed method based on a convolutional neural network (CNN) demonstrated a higher quality of reconstruction using less than 72 projections compared to conventional algorithms. The use of the new algorithm will significantly save time for conducting a single tomographic experiment.*

Key words: *convolutional neural network, neutron tomography*

Введение

Метод нейтронной томографии получил широкое распространение в таких областях как материаловедение, геология, палеонтология, археология. Благодаря большой глубине проникновения, чувствительности к легким элементам и хорошему контрасту для элементов с близкими атомными номерами нейтронная томография позволяет получать информацию о внутренней структуре массивных образцов без предварительной пробоподготовки. Это позволяет проводить неразрушающие исследования конструкционных материалов, метеоритов, горных пород, археологических находок [1–3]. Однако существенным недостатком метода нейтронной томографии является большая длительность эксперимента. Это накладывает ограничение на исследование больших серий образцов, а также не позволяет изучать особо ценные археологические артефакты из-за большой радиационной нагрузки. Таким образом существует необходимость развития метода нейтронной томографии [4], в том числе с помощью новых алгоритмов обработки данных, которые позволят сократить необходимое количество данных для качественной реконструкции [5–7]. Наиболее перспективными среди них являются алгоритмы на основе сверточных нейронных сетей. Благодаря им появляется возможность проводить томографическую реконструкцию из небольшого набора угловых радиографических проекций, что значительно сокращает время на проведение эксперимента. Тем не менее остается открытым вопрос определения минимально необходимого числа радиографических проекций для получения качественной реконструкции [8]. Данная статья посвящена качественной и количественной оценке эффективности алгоритма томографической реконструкции с применением сверточных нейронных сетей при работе с 9, 18, 36, 72, 144 и 216 радиографическими проекциями.

Экспериментальная часть

Эксперименты по нейтронной томографии проводились на трех установках: станция нейтронной радиографии и томографии НРТ на 14 канале реактора ИБР-2 (ОИЯИ, Дубна), станция нейтронной томографии ДРАКОН на восьмом горизонтальном экспериментальном

канале реактора ИР-8 (НИЦ “Курчатовский институт”, Москва), установка нейтронной радиографии и томографии ТИТАН на 1-ом канале исследовательского реактора ВВР-К (ИЯФ МЭ РК, Алмата). Время экспозиции для получения одного радиографического изображения с разрешением 2048×2048 пикселей варьировалось от 20 до 60 секунд. Для каждого исследуемого объекта снималось 360 проекций с угловым шагом 0.5° . Полученные в результате нейтронные радиографические проекции исследуемых объектов корректировались с учетом темнового тока камеры и нормировались на падающий пучок в программном пакете ImageJ. Далее наборы радиографических проекций конвертировались в синограммы. Всего для обучения сверточной нейронной сети были использованы результаты 28 экспериментов, что соответствует 35605 изображениям в обучающем наборе данных и 3050 изображениям для валидации.

Результаты

Для реконструкции трехмерных моделей объектов исследования из неполного набора нейтронных радиографических проекций была разработана и обучена сверточная нейронная сеть с архитектурой U-net [9]. На вход нейронной сети поступает неполный набор радиографических проекций, снятых с угловым шагом больше, чем 0.5° . Из этих проекций формируются синограммы: изображения, каждое из которых содержит информацию об одном слое трехмерной модели. Полученные синограммы восстанавливаются нейронной сетью до размера, соответствующего полному набору данных (360 проекций с шагом 0.5°), а затем реконструируются алгоритмом обратного проецирования (filtered back projection, FBP) в трехмерную модель. Для оценки эффективности разработанного алгоритма выполнялась реконструкция фантомного изображения из неполного набора радиографических проекций стандартным методом и с применением нейронной сети (Рис. 1). Количественная оценка качества реконструкции выполнялась с помощью индекса структурного сходства (structural similarity index measure, SSIM).

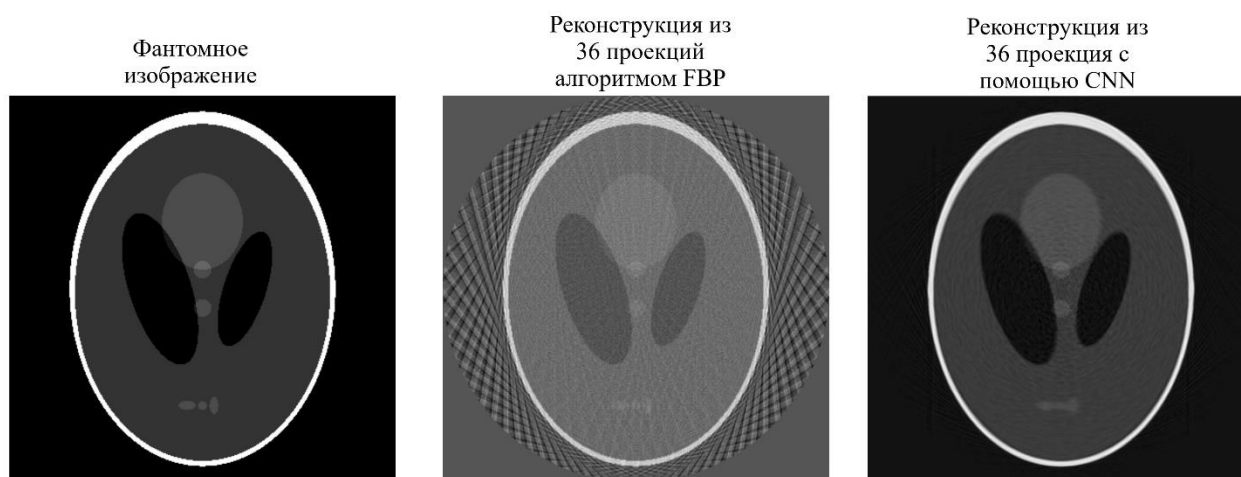


Рис. 1. Качественная оценка эффективности работы сверточной нейронной сети на примере реконструкции фантомного изображения из 36 радиографических проекций

Для определения минимально необходимого числа нейтронных радиографических проекций для качественной реконструкции нейронная сеть U-net была обучена на шести наборах данных, соответствующих 2,5 %, 5 %, 10 %, 20 %, 40 % и 60 % данных. Далее точность реконструкции с помощью нейронной сети сравнивалась со стандартными алгоритмами обратного проецирования и алгебраической реконструкции (simultaneous algebraic reconstruction technique, SART). Было показано, что при использовании 2,5 %, 5 %, 10 % и 20 % радиографических проекций алгоритм с применением CNN дает более высокое качество реконструкции (Рис. 2). По графику видно, что на данный момент оптимальной является

реконструкция из 72 проекций. Таким образом применение алгоритма на основе сверточной нейронной сети позволит экономить 80% времени на проведение нейтронного томографического эксперимента.

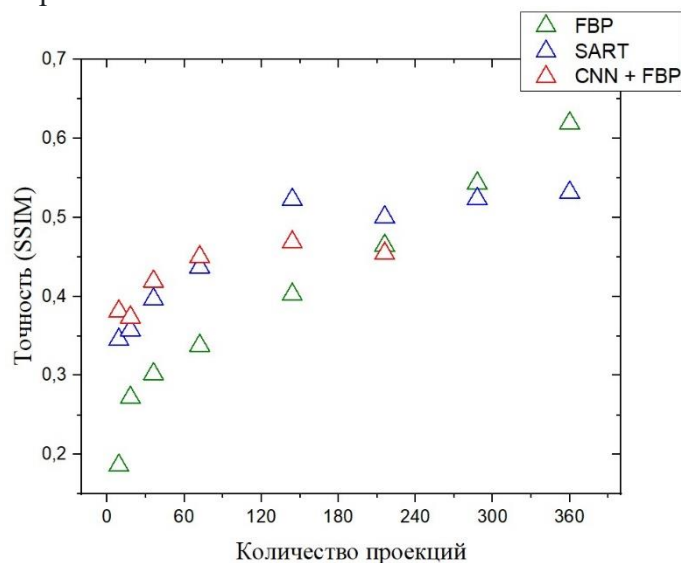


Рис. 2. Зависимость точности реконструкции от количества используемых радиографических проекций для различных алгоритмов реконструкции

Заключение

В результате работы был разработан и применен новый алгоритм томографической реконструкции нейтронных данных на основе сверточной нейронной сети из неполного набора радиографических проекций. Была показана эффективность нового алгоритма при реконструкции из 72 проекций и меньше. Применение разработанного алгоритма дает возможность существенно сократить время проведения нейтронных томографических экспериментов.

Список литературы

1. Podurets K.M. et al. Modern Methods of Neutron Radiography and Tomography in Studies of the Internal Structure of Objects // Crystallography Reports. Pleiades journals. – 2021. – Vol. 66, № 2. – P. 254–266.
2. Bakirov B. et. al. Phase Composition and Its Spatial Distribution in Antique Copper Coins: Neutron Tomography and Diffraction Studies // Journal of Imaging. – 2021. – Vol. 7, № 8. – P. 1-10.
3. Kichanov S.E. et al. A structural insight into the Chelyabinsk meteorite: neutron diffraction, tomography and Raman spectroscopy study // SN Appl Sci. – 2019. – Vol. 1, № 12. – P. 1563.
4. Schulz M., Lehmann E., Losko A. Neutron imaging // Non-Destructive Material Characterization Methods. Elsevier. – 2024. – P. 205–247.
5. Dong J., Fu J., He Z. A deep learning reconstruction framework for X-ray computed tomography with incomplete data // PLoS One. Public Library of Science. – 2019. – Vol. 14, № 11. – P. 1-17.
6. Scatigno C., Festa G. Neutron Imaging and Learning Algorithms: New Perspectives in Cultural Heritage Applications // Journal of Imaging. – 2022. – Vol. 8, № 10. – P. 1-11.
7. Dong H. et al. A scalable neural network architecture for self-supervised tomographic image reconstruction // Digital Discovery. – 2023. – Vol. 2, № 4. – P. 967–980.
8. Micieli D. et. al. Accelerating Neutron Tomography experiments through Artificial Neural Network based reconstruction // Scientific Reports. – 2019. – Vol. 9, № 1. – P. 1–12.
9. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // Lecture Notes in Computer Science. – 2015. – Vol. 9351. – P. 234–241.