

Сегментация кольцевых артефактов на микротомографических изображениях свёрточными нейронными сетями

А.С. Корнилов^{1,2}, И.В. Сафонов¹, И.В. Якимчук¹

¹Московский научно-исследовательский центр Шлюмберже, Пудовкина 13, Москва, Россия, 119285

²Национальный исследовательский ядерный университет «МИФИ», Каширское шоссе 31, Москва, Россия, 115409

Аннотация. Кольцевые артефакты на изображениях рентгеновской микротомографии ведут к ошибкам при интерпретации и дальнейшем использовании данных, например, в построении цифровых моделей образцов горных пород. Ранее был предложен алгоритм детектирования кольцевых артефактов с помощью согласованной фильтрации слоёв изображения в полярной системе координат. Однако данный подход имеет ряд недостатков и ограничений. Предлагается способ сегментации, основанный на применении свёрточных нейронных сетей. Рассматриваются две архитектуры сетей: SegNet и U-net. Для создания репрезентативной обучающей выборки разработан алгоритм переноса кольцевых артефактов, детектированных существующим алгоритмом, с одного изображения на другое. Обученная модель успешно сегментирует кольцевые артефакты даже для таких образцов изображений и артефактов, которые отсутствовали в обучающей выборке. Разработанный алгоритм используется для оценки качества микротомографических изображений и локальной коррекции участков изображений, повреждённых кольцевыми артефактами.

1. Введение

В последнее десятилетие рентгеновская микротомография (микроКТ) активно используется для анализа образцов горных пород, почв, гранулированных материалов [1], в частности, для построения их трёхмерных моделей при цифровом исследовании керна [2]. Примером одного из применений таких цифровых моделей является моделирование течения многофазной жидкости [3]. Однако, микроКТ изображения подвержены влиянию множества артефактов [4], которые ухудшают качество цифровой модели. Одним из наиболее известных видов артефактов являются кольцевые (ring) артефакты, которые вызваны дефектными пикселями в детекторе [5]. Примеры подобных артефактов представлены на рисунке 5. Производители микроКТ систем используют ряд подходов к уменьшению количества и видимости кольцевых артефактов, например: случайные перемещения между моментами получения теневых проекций, постобработка теневых проекций перед реконструкцией. Сочетание этих подходов позволяет подавить большинство кольцевых артефактов. Тем не менее, часть кольцевых артефактов сохраняется.

Для детектирования и подавления оставшихся артефактов было предложено несколько алгоритмов, которые работают уже непосредственно с восстановленным изображением. Так в статье [6] предложен алгоритм обнаружения кольцевых артефактов, затем повреждённые участки изображения могут быть восстановлены различными *inpainting* алгоритмами [7, 8]. Также существует ряд алгоритмов фильтрации для подавления подобных артефактов [9-12]. Сравнительное исследование [13] показывает, что эффективность данных алгоритмов сильно зависит от их параметров, и для достижения хороших результатов необходимо регулировать параметры от изображения к изображению. Кроме того, так как в каждом из этих алгоритмов предполагается, что кольцевые артефакты расположены на окружностях с центром, находящемся в центре среза, то у них нет возможности устранить артефакты на вырезанном фрагменте изображения. Алгоритмы фильтрации изменяют всё изображение, а не только области, повреждённые кольцевыми артефактами.

Сложность разработки универсального алгоритма объясняется огромным многообразием изображений, которые могут поступать на вход. Данное многообразие объясняется не только разнообразием сканируемых образцов, но и особенностями различных микроКТ систем и параметрами алгоритмов реконструкции из теневых проекций. Кроме того, поскольку образец занимает не всё пространство изображения, то необходимо выполнить поиск области интереса, внутри которой будет производиться обнаружение артефактов.

В настоящее время широкое распространение получили алгоритмы машинного обучения. Глубокое обучение позволило достичь прорывных результатов в ряде задач компьютерного зрения. В частности, применение свёрточных нейронных сетей дало огромный прогресс в области сегментации изображений [14]. Качество работы алгоритмов машинного обучения значительным образом зависит от качества и объёма обучающей выборки. Чтобы обеспечить высокую точность, необходимо собрать репрезентативный набор данных. В данной работе предлагается способ создания репрезентативной выборки кольцевых артефактов на срезах микроКТ изображений, а также производится сравнение точности сегментации нейронными сетями с архитектурами SegNet [15] и U-net [16]. На рисунке 1 представлена диаграмма построения модели нейронной сети для устранения кольцевых артефактов.



Рисунок 1. Диаграмма построения модели нейронной сети для устранения кольцевых артефактов.

2. Генерация набора изображений с кольцевыми артефактами

На данный момент авторам неизвестен какой-либо представительный открытый набор микроКТ изображений, повреждённых кольцевыми артефактами. На сайте (www.digitalrocksportal.org) посвящённом задачам, связанным с “цифровым керном”, можно найти только несколько примеров подобных артефактов, например в изображениях, полученных в работе [17]. По этой причине было принято решение сформировать собственный набор данных на основе 8 реконструированных 3D изображений песка и песчаников. Каждое из них относилось к одному из пяти типов: песчаникам Buff Berea (BB), Bentheimer (BH), Fontainebleau (FB), Gravelite (GRV) или песку Unifrac (UFS). Более детальное описание каждого типа изображения и параметров съёмки содержится в статье [18]. На рисунке 2 приведены примеры фрагментов двумерных срезов каждого типа анализируемых микроКТ изображений: BB (2а), BH (2б), FB (2в), GRV (2г) и UFS (2д).

Каждое изображение имеет размер $3968 \times 3968 \times 1840$ вокселей и глубину цвета 8 бит на воксел. На всех изображениях присутствуют срезы, затронутые кольцевыми артефактами. Суммарное количество по всем изображениям составляет ~ 1500 кольцевых артефактов, чего недостаточно для целей глубокого обучения. Так при попытке обучения рассматриваемых моделей, используя только исходный набор изображений с артефактами, были получены нерелевантные результаты. По этой причине предлагается обогатить набор данных путём переноса артефактов с одних изображений на другие.

Первым шагом является составление базы имеющихся артефактов. Используя алгоритм сегментации [6], предложенный ранее, было получено 1440 изображений кольцевых артефактов и их масок в полярных координатах. Данный алгоритм состоит в преобразовании изображения в полярные координаты с последующей обработкой согласованным фильтром и пороговым отсечением, в результате которого получается маска артефактов. Как и другие алгоритмы, основанные на преобразовании среза в полярные координаты, данный подход не может работать с фрагментами изображения и плохо детектирует артефакты в центре среза.

На рисунке 3 представлены некоторые типы полученных артефактов с соответствующими им масками: пример светлого артефакта (3а); пример тёмного артефакта (3в); пример артефакта, который переходит из светлого в тёмный и обратно (3д).




Рисунок 2. Примеры 1 мм^2 фрагментов слоев анализируемых микроКТ изображений.

На каждый слой I исходных изображений было нанесено $K_a = 100$ артефактов, случайно выбранных из созданной базы. Артефакт I_a под номером i с соответствующей ему маской MSK_a наносится на слой в полярных координатах I_{i-1}^p с началом в координатах (r_a, c_a) :

$$I_i^p(r, c) = \begin{cases} I_{i-1}^p(r, c) + \Delta_a(r - r_a, c - c_a) : r \in [r_a, r_a + N_a] \wedge c \in [c_a, c_a + M_a] \\ I_{i-1}^p(r, c) : \text{иначе} \end{cases} \quad (1)$$

где (r, c) – координаты пикселя слоя; $r = 0 \dots N-1$, $c = 0 \dots M-1$; N , N_a – количество строк в изображении слоя и артефакта; M , M_a – количество столбцов в изображении слоя и артефакта; Δ_a – изображение размера $N_a \times M_a$, определяемое формулами (2) и (3), каждая строка которого представляет разность между строкой средних значений по k_r строкам I_a и её медианным значением:

$$\Delta_a(r, c) = \mu(r, c) - \text{median}_c[\mu(r, c)], \quad (2)$$

$$\mu(r, c) = M[I_a(r, c), I_a(r+1, c), \dots, I_a(r+k_r, c)], \quad (3)$$

где $r = 0 \dots N_a-1$, $c = 0 \dots M_a-1$; $M[\bullet]$ – обозначает среднее значение; $\text{median}_c[\bullet]$ – обозначает медианное значение относительно столбцов.




Рисунок 3. Примеры изображений и масок из составленной базы кольцевых артефактов.




Рисунок 4. Фрагмент среза изображения и маски артефактов.

Координата r_a начала артефакта в полярной системе выбирались случайным образом в диапазоне $[0, N-N_a]$, а координата c_a изменялась с шагом, случайно выбираемым в диапазоне $[s_{ca1}, s_{ca2}]$ на каждой итерации добавления артефакта. Начальное значение c_a в нашем случае было установлено равным 200, $s_{ca1} = 20$, $s_{ca2} = 150$, а $k_r = 10$. В результате, после преобразования изображений из полярных координат были получены срезы с большим количеством кольцевых артефактов. Дополнительно были получены маски расположения артефактов. Пример фрагмента с перенесёнными артефактами и его маска представлены на рисунке 4. Полученные изображения использовались в целях обучения и верификации рассматриваемых нейронных сетей.

3. Рассматриваемые архитектуры нейронных сетей

3.1. Основные идеи

На данный момент глубокое обучение активно применяется для сегментации изображений. В частности, для этих целей успешно используют полносвязные свёрточные нейронные сети [19, 20]. Для сегментации разного рода томографических изображений в последнее время применяются архитектуры SegNet [15] и U-net [16], а также их различные модификации [18]. Кроме этого, реализации данных моделей поддерживаются подавляющим большинством фреймворков машинного обучения. Это позволяет относительно просто внедрить обученную сеть в существующее программное обеспечение, например, в реализацию оценки качества микроКТ изображений [6] средствами OpenCV. По данной причине в статье оценивается эффективность применения именно этих архитектур для сегментации кольцевых артефактов на микроКТ изображениях горных пород.

Поскольку образец занимает не всё пространство изображения, сначала применяется алгоритм выделения области интереса [21]. Для обучения и валидации нейронных сетей

использовались непересекающиеся фрагменты срезов размером 512×512 пикселей, более 80% которых находятся внутри области интереса.

3.2. Архитектуры сетей

SegNet [15] является автокодировщиком, основанным на свёрточной нейронной сети. Его архитектура симметрична, за исключением слоя мягкого максимума (Softmax) на выходе сети. Сама сеть состоит из последовательности свёрток и субдискретизирующих слоёв (max pooling) или слоёв, повышающих дискретизацию (upsampling). Кроме этого, присутствуют активационные слои усечённого линейного преобразования (ReLU) [22] и слои батч-нормализации [23]. Отличие данной сети от традиционного автокодировщика заключается в том, что его слои, повышающие дискретизацию, соединены с соответствующими слоями субдискретизирующих слоёв. При обучении upsampling слои не обучаются, а получают от max pooling слоёв информацию (индексы активированных пикселей) о том, как повысить размерность и восстановить утерянную топологию (pool indices).

Архитектура сети U-net имеет схожую структуру, но вместо upsampling слоя использует слои обратных свёрток (deconvolution) [24]. Главное же её отличие состоит в том, что вместо того, чтобы соединять max pooling и upsampling слои, в данной архитектуре предлагается объединять карты признаков после обратных свёрток с соответствующими им картами признаков, полученными до субдискретизаций. Это позволяет модели на этапе восстановления маски использовать забытые признаки, что должно улучшать качество сегментации.

3.3. Стратегия обучения

Несмотря на то, что в сгенерированной выборке каждый срез покрыт множеством артефактов, отношение суммарного количества пикселей масок, которые не соответствуют артефактам, к суммарному количеству пикселей, которые им соответствуют, около 68. Поэтому, для обучения предлагается использовать функцию потерь для сильно несбалансированных размеров объектов [25]:

$$L = M_x \left[\omega_{WBCE} L'_{WBCE} + \omega_{LDice} L'_{LDice} \right], \quad (4)$$

где $M_x[\cdot]$ – обозначает среднее значение относительно предсказаний x ; L_{WBCE} – взвешенная функция потерь бинарной кросс-энтропии, представленная формулой (5); ω_{WBCE} , ω_{LDice} – весовые коэффициенты; γ – коэффициент для контроля нелинейности; L_{LDice} – логарифмическая функция потерь, основанная на мере Дайса, представленная формулой (6).

$$L_{WBCE} = -(\omega_p y(x) \ln(x) + (1 - y(x)) \ln(1 - x)), \quad (5)$$

где ω_p – весовой коэффициент для балансировки классов; x – предсказание, полученное при помощи сигмоидальной функции; $y(x)$ – бинарное целевое значение x .

$$L_{LDice} = -\ln \left(\frac{2 \sum_x (y(x)x) + 1}{(\sum_x y(x) + x) + 1} \right). \quad (6)$$

Значение весового коэффициента $\omega_p = 68$ было установлено в соответствии с отношением количеств пикселей каждого класса, а значения $\omega_{WBCE} = 0.7$, $\omega_{LDice} = 0.3$ и $\gamma = 0.3$.

Обучающая выборка была сформирована из фрагментов срезов 7 3D изображений с нанесёнными артефактами из 85% базы кольцевых артефактов. Остальные 15% артефактов использовались для нанесения на срезы оставшегося изображения, фрагменты срезов которого использовались для валидации. Для создания валидационной выборки использовалось изображение образца наименее похожего на остальные – UFS. Размер обучающей и валидационной выборок составил 295319 и 38640 фрагментов соответственно. В качестве метода оптимизации использовался Adam [26] со скоростью обучения (learning rate) равной 10^{-4} . После каждой итерации обучения из валидационной выборки случайно выбиралось 1000 изображений со своими масками, для них рассчитывалась мера Дайса, представленная формулой (7). Обучение прекращалось тогда, когда разность этой меры на текущей и предыдущей итерации становилась ниже 10^{-3} .

$$Dice = \frac{2\sum_x (y(x)x) + 1}{(\sum_x y(x) + x) + 1}. \quad (7)$$

4. Результаты

Сеть обучалась на двух видеокάρтах NVIDIA GeForce GTX 1080 Ti. За одну итерацию на видеокарты загружалось максимально возможное количество изображений, суммарно равное 10. Для обучения использовался фреймворк PyTorch [27].

В таблице 1 представлены меры Дайса (Dice) и площади под ROC-кривой (AUC-ROC) [28, 29], рассчитанные после окончания обучения по полной валидационной выборке изображений с нанесёнными кольцевыми артефактами.




Рисунок 5. Примеры фрагментов изображений, которые не участвовали в процессе создания обучающей выборки (а), (г) (ж); результаты ручной разметки (зелёный цвет), сегментация при помощи U-net (красный цвет), их пересечение (жёлтый цвет) (б), (д), (з); результат устранения артефакта на основе полученной сегментации (в), (е), (и).

Кроме этого, для 20 срезов из различных 3D изображений, которые не участвовали в обучении, были вручную размечены области с артефактами. В таблице 2 представлены меры оцениваемых моделей, рассчитанные на основе данной разметки. Поскольку при процедуре валидации на не участвовавших в созданной выборке изображениях для архитектуры U-net были получены относительно более высокие значения обеих метрик, то именно эта архитектура является более предпочтительной для сегментации кольцевых артефактов. В первом столбце на рисунке 5 представлены примеры фрагментов срезов данных изображений; на рисунках второго столбца: ручная разметка, обозначенная зелёным цветом и полученная при помощи U-net сегментация, обозначенная красным цветом; а также результаты устранения артефактов [8], на основе данной сегментации, представлены на рисунках в третьем столбце. Полученные относительно низкие значения метрики Дайса, при этом, обусловлены тем, что границы артефактов чётко не определены, и получаемые при помощи нейронных сетей сегменты, как можно видеть из примеров на рисунке 5, занимают большую площадь, чем размеченные.

Таблица 1. Метрики, рассчитанные на валидационной выборке с нанесёнными артефактами.

Модель	Dice	AUC-ROC
SegNet	0.70	0.92
U-net	0.75	0.93

Таблица 2. Метрики, рассчитанные на основе ручной разметки.

Модель	Dice	AUC-ROC
SegNet	0.43	0.75
U-net	0.57	0.88

5. Заключение

Проведённое исследование показало, что в случае создания большой представительной обучающей выборки методы глубокого машинного обучения могут быть успешно применены для задачи сегментации кольцевых артефактов на микроКТ изображениях образцов горных пород, почв и гранулированных материалов. В частности, свёрточная сеть U-net обеспечивает достаточно хорошие результаты сегментации как на основе визуального анализа, так и в соответствии со значениями метрик Дайса и AUC-ROC.

Для создания выборки слоёв с большим количеством кольцевых артефактов предложен алгоритм переноса кольцевых артефактов, детектированных разработанным ранее алгоритмом [6]. Обученная модель позволяет успешно сегментировать артефакты и на тех изображениях образцов и артефактов, которые никак не использовались для создания обучающей выборки. Продемонстрированы примеры локальной коррекции артефактов на основе полученной сегментации. Также предложенный алгоритм может использоваться для оценки качества микроКТ изображений, при этом он лишён недостатков ранее предложенного алгоритма, связанных с преобразованием в полярные координаты. Остаётся большое пространство для улучшений, как алгоритма обогащения обучающей выборки, так и стратегии обучения. Например, для более точного получения масок артефактов при составлении их базы можно использовать разницу между соседними слоями – без артефакта и с артефактом. Также, предполагается, что после улучшения качества переноса артефактов, произойдет увеличение точности при замене функции потерь бинарной кросс-энтропии в формуле (4) на focal loss [30].

6. Литература

- [1] Safonov, I. Algorithms for 3D Particles Characterization Using X-Ray Microtomography in Proppant Crush Test / I. Safonov, I. Yakimchuk, V. Abashkin // *Journal of Imaging*. – 2018. – Vol. 4(11). – P. 134.
- [2] Koroteev, D.A. Application of digital rock technology for chemical EOR screening / D.A. Koroteev, O. Dinariev, N. Evseev, D.V. Klemin, S. Safonov, O.M. Gurpinar, S. Berg, C. van Kruijsdijk, M. Myers, L.A. Hathon, H. de Jong, R. Armstrong // *Proceedings of the SPE Enhanced Oil Recovery Conference*, 2013.
- [3] Dinariev, O. Multiphase flow modeling with density functional method / O. Dinariev, N. Evseev // *Computational Geosciences*. – 2016. – Vol. 20(4). – P. 835-856.
- [4] Barrett, J.F. Artifacts in CT: recognition and avoidance / J.F. Barrett, N. Keat // *Radiographics*. – 2004. – Vol. 24(6). – P. 1679-1691.
- [5] Buzug, T.M. *Computed Tomography: From Photon Statistics to Modern Cone-Beam CT* / T.M. Buzug – New York: Springer Science & Business Media, 2008.
- [6] Kornilov, A. Blind Quality Assessment for Slice of Microtomographic Image / A. Kornilov, I. Safonov, I. Yakimchuk // *24th Conference of Open Innovations Association (FRUCT)*, 2019. – P. 170-178.
- [7] Telea, A. An image inpainting technique based on the fast marching method / A. Telea // *Journal of graphics tools*. – 2004. – Vol. 9(1). – P. 23-34.

- [8] Bertalmio, M. Navier-stokes, fluid dynamics, and image and video inpainting / M. Bertalmio, A.L. Bertozzi, G. Sapiro // Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. – 2001. – Vol. 1. – P. I-I.
- [9] Prell, D. Comparison of ring artifact correction methods for flat-detector CT / D. Prell, Y. Kyriakou, W.A. Kalender // Physics in Medicine & Biology. – 2009. – Vol. 54(12). – P. 3881.
- [10] Sijbers, J. Reduction of ring artefacts in high resolution micro-CT reconstructions / J. Sijbers, A. Postnov // Physics in Medicine & Biology. – 2004 – Vol. 49(14). – P. N247.
- [11] Axelsson, M. Reduction of ring artifacts in high resolution X-ray microtomography images / M. Axelsson, S. Svensson, G. Borgefors // Joint Pattern Recognition Symposium. – 2006. – P. 61-70.
- [12] Lyckegaard, A. Correction of ring artifacts in X-ray tomographic images / A. Lyckegaard, G. Johnson, P. Tafforeau // Int. J. Tomo. Stat. – 2011 – Vol. 18. – P. 1-9.
- [13] Anas, E.M.A. Comparison of ring artifact removal methods using flat panel detector based CT images / E.M.A. Anas, J.G. Kim, S.Y. Lee, M.K. Hasan // Biomedical engineering online. – 2011. – Vol. 10(1). – P. 72.
- [14] Litjens, G. A survey on deep learning in medical image analysis / G. Litjens, T. Kooi, B.E. Bejnordi, A.A.A. Setio, F. Ciompi, M. Ghahfoorian, J.A.W.M. van der Laak, B. van Ginneken, C.I. Sánchez // Medical image analysis. – 2017. – Vol. 42. – P. 60-88.
- [15] Badrinarayanan, V. Segnet: A deep convolutional encoder-decoder architecture for image segmentation / V. Badrinarayanan, A. Kendall, R. Cipolla // IEEE transactions on pattern analysis and machine intelligence. – 2017. – Vol. 39(12). – P. 2481-2495.
- [16] Ronneberger, O. U-net: Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // International Conference on Medical image computing and computer-assisted intervention, 2015. – P. 234-241.
- [17] Carrel, M. Biofilm imaging in porous media by laboratory X-Ray tomography: Combining a non-destructive contrast agent with propagation-based phase-contrast imaging tools / M. Carrel, M.A. Beltran, V.L. Morales, N. Derlon, E. Morgenroth, R. Kaufmann, M. Holzner // PloS one. – 2017. – Vol. 12(7).
- [18] Varfolomeev, I. An Application of Deep Neural Networks for Segmentation of Microtomographic Images of Rock Samples. / I. Varfolomeev, I. Yakimchuk, I. Safonov // Computers. – 2019. – Vol. 8(4). – P. 72.
- [19] Long, J. Fully convolutional networks for semantic segmentation / J. Long, E. Shelhamer, T. Darrell // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2015. – P. 3431-3440.
- [20] Vasilchenko, V.A. Algorithmization of the process of recognition of states of living objects based on special x-ray images / V.A. Vasilchenko, V.L. Burkovsky, A.D. Danilov // Computer Optics. – 2019. – Vol. 43(2). – P. 296-303.
- [21] Kornilov, A.S. Selection in a 3D microtomographic image the region with the highest quality / A.S. Kornilov, I.V. Safonov, A.V. Goncharova, I.V. Yakimchuk // CEUR Workshop Proceedings. – 2019. – Vol. 2391. – P. 160-168.
- [22] Nair, V. Rectified linear units improve restricted boltzmann machines / V. Nair, G.E. Hinton // Proceedings of the 27th international conference on machine learning. – 2010. – P. 807-814.
- [23] Ioffe, S. Batch normalization: Accelerating deep network training by reducing internal covariate shift / S. Ioffe, C. Szegedy // International Conference on Machine Learning. – 2015. – Vol. 37. – P. 448-456.
- [24] Noh, H. Learning deconvolution network for semantic segmentation / H. Noh, S. Hong, B. Han // Proceedings of the IEEE international conference on computer vision, 2015. – P. 1520-1528.
- [25] Wong, K.C. 3d segmentation with exponential logarithmic loss for highly unbalanced object sizes / K.C. Wong, M. Moradi, H. Tang, T. Syeda-Mahmood // International Conference on Medical Image Computing and Computer-Assisted Intervention, 2018. – P. 612-619.
- [26] Kingma, D.P. Adam: A method for stochastic optimization / D.P. Kingma, J. Ba // Proceedings of the 3rd International Conference on Learning Representations, 2014.

- [27] Paszke, A. Automatic differentiation in pytorch / A. Paszke, S. Gross, S. Chintala, G. Chanan, E. Yang, Z. DeVito, Z. Lin, A. Desmaison, L. Antiga, A. Lerer // NIPS Workshop Autodiff, 2017.
- [28] Huang, J. Using AUC and accuracy in evaluating learning algorithms / J. Huang, C.X. Ling // IEEE Transactions on knowledge and Data Engineering. – 2005. – Vol. 17(3). – P. 299-310.
- [29] López, V. An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics / V. López, A. Fernández, S. García, V. Palade, F. Herrera // Information sciences. – 2013. – Vol. 250 – P. 113-141.
- [30] Lin, T.Y. Focal loss for dense object detection / T.Y. Lin, P. Goyal, R. Girshick, K. He, P. Dollár // Proceedings of the IEEE international conference on computer vision, 2017. – P. 2980-2988.

Ring artifacts segmentation on microtomographic images by convolutional neural networks

A.S. Kornilov^{1,2}, I.V. Safonov¹, I.V. Yakimchuk¹

¹Schlumberger Moscow Research, Pudovkina 13, Moscow, Russia, 119285

²National Research Nuclear University MEPhI, Kashirskoe shosse 31, Moscow, Russia, 115409

Abstract. Ring artifacts in X-ray microtomographic images can lead to errors in data interpretation and further use, e.g. in the construction of digital twins of rock samples. Previously, we considered an algorithm for detecting ring artifacts by means of matching filtering of image slices in a polar coordinate system. However, that approach has several disadvantages and limitations. In this paper, we propose the segmentation method based on convolutional neural networks. Two network architectures are considered: SegNet and U-net. To create a big and representative training dataset, we propose an algorithm for transferring ring artifacts detected by the existing approach from one image to another. The trained model successfully segments ring artifacts even for such sample images and artifacts that were not in the training set. The developed algorithm is used to assess the quality of microtomographic images and local correction of image regions damaged by ring artifacts.