

Алгоритм сегментации тканей почки на КТ-изображениях на базе сверточной нейронной сети U-Net

Аннотация

Исследовано влияние различных операций предварительной обработки изображений, а также различных параметров нейронной сети архитектуры U-Net на точность сегментации тканей почки на КТ-изображениях. Установлено, что наибольшая точность сегментации достигается при последовательном применении к каждому изображению операции двухуровневого ограничения по яркости, спецификации гистограммы яркости и приведения динамического диапазона яркости к интервалу $[-1, 1]$. В отличие от существующих подходов к сегментации изображений при помощи нейронных сетей в рассматриваемой работе после двухуровневого ограничения фоновым пикселям присваиваются значения случайных величин в диапазоне от -1 до 1 , имеющих равномерное распределение вероятностей. Кроме того, используется операция маскирования областей изображения, что позволило повысить стабильность обучения нейронной сети.

Введение

Сегментация тканей почки – важный этап в анализе КТ-снимков. Ручная сегментация является трудоемкой задачей, результат которой сильно зависит от квалификации и опыта врача. Из-за слабой формализуемости задачи сегментации в ее решении широко применяются подходы на базе машинного обучения. Так, хорошие результаты показывают сверточные нейронные сети на базе архитектуры U-Net, подробное описание которой дано в работе [1]. При этом решающее значение имеет выбор алгоритма предобработки, выравнивающего статистические характеристики изображений обучающей выборки. Разработка данного алгоритма для сегментации тканей почки и опухоли на КТ-изображениях органов брюшной полости посредством нейронной сети U-Net является предметом настоящей статьи.

Материал и методы

Для проведения исследований использовалась база данных KiTS (Kidney Tumor Segmentation) [2], [3]. Она содержит порядка 3 000 изображений томографических срезов разрешением 512×512 пикселей, полученных от трехсот уникальных пациентов с раком почки. Изображения получены в артериальной фазе КТ-обследования. Для каждого КТ-снимка приводятся изображения масок, содержащие пиксели с тремя значениями яркостей, соответствующих тканям почки, злокачественному образованию и остальным тканям забрюшинного пространства (рис. 1).




Рис. 1. Изображение томографического снимка и его бинарной маски из базы данных KiTS (выделены ткани почки и злокачественное новообразование)

Дополнительно использовались КТ-изображения от шести уникальных пациентов, также полученные в артериальной фазе в урологическом отделении ГБУ РМЭ Республиканская клиническая больница. Для данных изображений сотрудниками ПГТУ были сформированы маски с размеченными областями тканей почки, злокачественных новообразований и остальных тканей забрюшинного пространства.

Для исследования влияния различных операций предварительной обработки изображений, а также различных параметров нейронной сети архитектуры U-Net на точность сегментации тканей почки на КТ-изображениях использовалось 190 изображений из базы данных KiTS и 60 изображений из базы данных ГБУ РМЭ Республиканская клиническая больница. Отметим, что в наших экспериментах любые попытки обучить нейронную сеть на указанных КТ-изображениях без предварительной обработки оканчивались неудачей, поэтому к изображениям для создания условий, повышающих эффективность и качество выделения и распознавания изучаемых объектов, применялись различные комбинации операций предварительной обработки изображений, такие как двухуровневое ограничение по яркости, маскирование областей, спецификация гистограммы, рандомизация фоновых пикселей, линейное изменение динамического диапазона яркостей. В результате исследования различных комбинаций операций предварительной обработки изображений для сегментации тканей почки при помощи нейронной сети U-Net предложен алгоритм, представленный на рис. 2.



Рис. 2. Структурная схема алгоритма сегментации тканей почки на КТ-изображении при помощи нейронной сети U-Net

На первом шаге работы алгоритма выполняется двухуровневое ограничение по яркости пикселей КТ-изображения. Значения яркостей пикселей по шкале единиц Хаунсфилда на КТ-изображениях находятся в диапазоне от -2047 до 2048 , при этом тканям почки соответствуют пиксели в диапазоне яркостей в интервале $[-200, 500]$ [4]. Это затрудняет процесс обучения нейронной сети для сегментации тканей почки, поскольку большая часть информации, поступающая на ее вход как в процессе обучения, так и в процессе распознавания, соответствует другим тканям органов забрюшинного пространства. Поэтому логичным шагом на этапе предварительной обработки изображений является двухуровневое ограничение по яркости пикселей вне диапазона $[-200, 500]$.

В отличие от существующих подходов к сегментации тканей почки на КТ-изображениях, использующих ограничения по яркости, в данной работе к полученным изображениям применялась операция маскирования, т. е. пиксели вне указанного диапазона в дальнейшем не использовались для вычисления статистических характеристик изображения. Кроме того, далее этим пикселям присваивались случайные значения, равномерно распределенные в диапазоне $[-1, 1]$. Подобный подход использовался в работе [5] для деперсонализации медицинских изображений при объемном рендеринге. В нашем случае данная операция позволила повысить качество обучения нейронной сети, после ее использования нейронная сеть успешно обучалась в 9 из 10 случаев.

Далее, для того чтобы привести распределения яркостей пикселей различных КТ-изображений к одному виду, к каждому срезу применялась операция стандартизации гистограммы [6]-[8]. Для этого из обучающей выборки случайным образом выбирается одно изображение, к виду гистограммы яркостей этого изображения приводятся гистограммы яркостей остальных изображений. Отметим, что операция стандартизации применяется к маскированному изображению, т. е. все статистические характеристики изображений определяются лишь для пикселей в диапазоне яркостей $[-200, 500]$, выделенных на этапе двухуровневого ограничения яркостей. К этим же пикселям применяются операции нелинейных преобразований в соответствии с процедурой стандартизации гистограммы.

Завершающим шагом предварительной обработки является приведение динамического диапазона яркости маскированного изображения к интервалу $[-1, 1]$. Данное преобразование повышает стабильность оптимизации моделей глубокого обучения путем снижения проблемы взрывающихся градиентов [9].

Градиентом в нейронных сетях называется вектор частных производных функции потерь по весам нейронной сети. Он указывает направление наибольшего роста этой функции для всех весов по совокупности. Градиент считается в процессе тренировки нейронной сети и используется в оптимизаторе весов для улучшения качества модели. Взрывающимся градиентом называется явление нестабильности алгоритма обучения нейронной сети вследствие накопления больших значений градиента, что приводит к сильному изменению ее весов и нестабильности алгоритма обучения.

Указанные выше трансформации позволили обучать сверточные нейронные сети архитектуры U-Net на небольшом наборе данных (порядка 200 образцов), а также сделать более стабильным процесс обучения нейронной сети. Как правило, нейронные сети успешно обучались в 9 из 10 случаев. В то же время процесс обучения нейронной сети редко оканчивался удачно, если исключить из описанного выше алгоритма один из этапов обработки изображений.

Результаты

Для исследования влияния различных операций предварительной обработки на точность сегментации тканей почки на КТ-изображениях при помощи сверточных нейронных сетей на базе архитектуры U-Net был поставлен ряд экспериментов. С использованием языка программирования Python и его библиотек TensorFlow, OpenCV, scikit-image была спроектирована сверточная нейронная сеть с архитектурой U-Net, содержащая 6 слоев, в каждом из которых выполнялось по 96, 256, 384, 384, 256, 96 операций свертки соответственно. Во всех слоях использовалось ядро свертки 3×3 , между первым, вторым и третьем слоями выполнялась операция пулинга [1], а между четвертым, пятым и шестым – операция повышения разрешения изображения [9]. С использованием данной нейронной сети было поставлено 6 экспериментов по ее обучению и последующей сегментации тканей почки, отличающихся друг от друга используемыми операциями предварительной обработки изображений. В качестве функции ошибки нейронной сети использовался коэффициент Дайса [10], весовые коэффициен-

ты нейронной сети изменялись каждый раз после подачи нового образца. Графики процесса обучения нейронной сети для 5 экспериментов показаны на рис. 3.

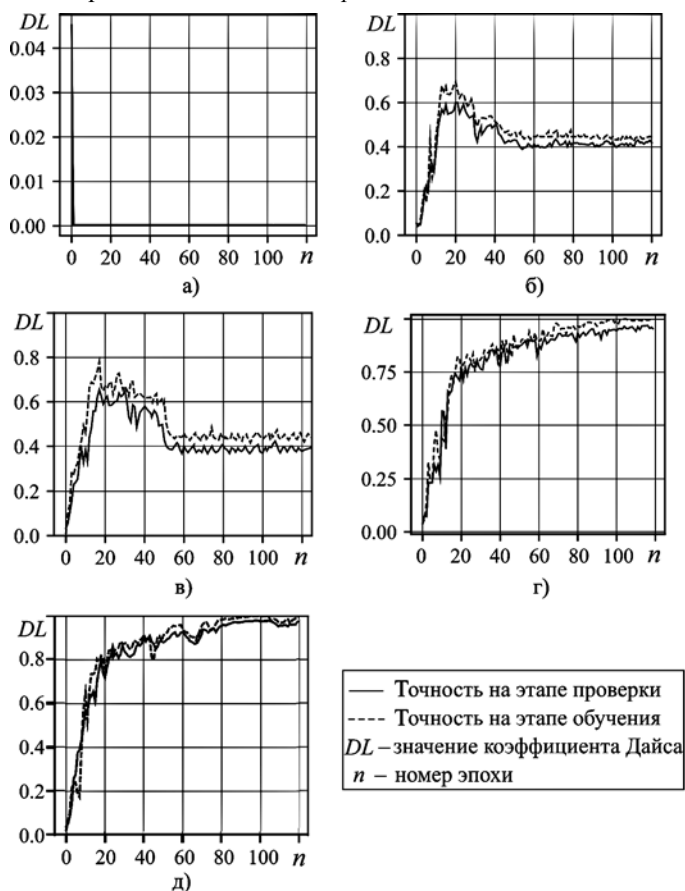


Рис. 3. Графики обучения сверточной нейронной сети при различных операциях предварительной обработки изображений: а) первый эксперимент; б) второй эксперимент; в) третий эксперимент; г) четвертый эксперимент; д) пятый эксперимент

В первом эксперименте на вход нейронной сети подавали исходные изображения, динамический диапазон которых был приведен к интервалу $[-1, 1]$. Как видно из рис. 3, в этом случае нейронная сеть не обучалась.

Во втором эксперименте использовали двухуровневое ограничение по яркости пикселей и изменение динамического диапазона к интервалу $[-1, 1]$, как в первом эксперименте.

В третьем эксперименте на этапе предварительной обработки изображений применяли двухуровневое ограничение по яркости пикселей в диапазоне $[-200, 500]$ без маскирования областей, спецификацию гистограммы и изменение динамического диапазона входных данных к интервалу $[-1, 1]$.

Операции предварительной обработки в четвертом эксперименте аналогичны тем, что использовались в третьем, за исключением того, что в нем использовалось двухуровневое ограничение по яркости с маскированием. Как видно из рис. 3, операция маскирования в целом улучшает качество сегментации тканей почки при помощи сверточной нейронной сети, поэтому она использовалась во всех последующих экспериментах.

Операции предварительной обработки изображений в пятом эксперименте были аналогичны четвертому, за исключением того, что после двухуровневого ограничения по яркости фоновым пикселям присваивались случайные значения яркостей. Отметим, что эта процедура никак не влияет на результаты стандартизации гистограммы и нормализации данных, поскольку в нашей работе используются маскированные изображения и преобразованиям подвергаются лишь пиксели из области интереса. Из рис. 3 видно, что наилучшее качество обучения нейронной сети наблюдается в четвертом и пятом

экспериментах, однако использование операции рандомизации фоновых пикселей в пятом эксперименте позволило повысить стабильность обучения нейронной сети. Так, в четвертом эксперименте нейронная сеть успешно обучалась лишь в 50 % случаях, а в пятом – уже в 90 %.

Последующие эксперименты были связаны с исследованием влияния параметров нейронной сети U-Net на качество сегментации тканей почки. При этом использовались операции предварительной обработки, представленные на рис. 2. 200 изображений из нашей базы данных использовались в качестве обучающей выборки, 50 – в качестве проверочной. Всего было исследовано три конфигурации нейронной сети (табл. 1).

Из таблицы видно, что полученное качество сегментации является приемлемым для последующего построения трехмерных моделей почек и дифференциации их тканей методами машинного обучения. На рис. 4 изображены трехмерные модели почек, построенные по результатам ручной сегментации их тканей и сегментации тканей при помощи предложенного алгоритма.

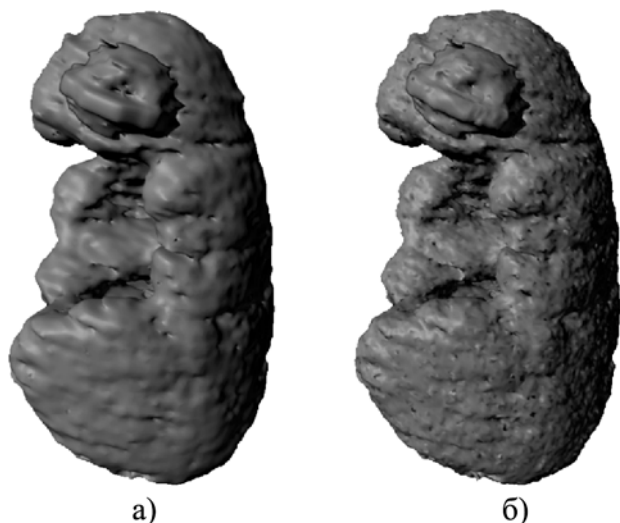


Рис. 4. Трехмерные модели почки: а) модель, построенная по результатам ручной сегментации тканей почки; б) модель, построенная по результатам сегментации тканей почки при помощи предложенного в статье алгоритма

Заключение

Предложенный алгоритм сегментации тканей почки на КТ-изображениях при помощи нейронной сети с архитектурой U-Net представляет собой достаточно удачную комбинацию операций предварительной обработки, с использованием которой удалось получить хорошие результаты сегментации и обеспечить стабильность обучения нейронной сети. Дальнейшее развитие указанных в статье подходов к сегментации тканей почки будет связано со значительным увеличением объемов обучающей и тестовой выборок, а также с исследованием применимости трехмерных сверточных нейронных сетей для сегментации тканей почки [10]. Кроме того, научный интерес представляет автоматическая сегментация анатомических структур почки, таких как корковое вещество, почечная артерия, почечная вена, почечная лоханка, почечная чашка и мочеточник, в различных фазах КТ-исследования при использовании контрастирующих веществ.

Список литературы:

1. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation / 18th International Conference Medical Image Computing and Computer-Assisted Intervention – MICCAI. 2015. Munich, Germany. PP. 234-241.
2. The KiTS19 Challenge Data: 300 Kidney Tumor Cases with Clinical Context, CT Semantic Segmentations, and Surgical Outcomes / <https://github.com/neheller/kits19>. Retrieved January 25, 2021.
3. Heller N et al. The KiTS19 Challenge Data: 300 Kidney Tumor Cases with Clinical Context, CT Semantic Segmentations, and Surgical Outcomes. 2019 / ArXiv preprint arXiv:1904.00445.
4. Da Cruz L.B. et al. Kidney segmentation from computed tomography images using deep neural network // Computers in Biology and Medicine. 2020. Vol. 123. P. 103906.
5. Вимкер Р., Буелов Т., Клиндер Т., Бергтольдт М., Вахтер-Штеле И. Визуальная деперсонализация массивов медицинских данных для защиты при объемном 3d-рендеринге / Патент RU2017102244А; заявл. 22.06.2015; опубликовано 26.07.2018. Бюл. № 21.
6. Гонсалес Р., Вудс Р. Цифровая обработка изображений. – М.: Техносфера, 2006. 1072 с.
7. Сойфер В.А. и др. Введение в цифровую обработку сигналов и изображений: повышение качества и оценивание геометрических параметров изображений. – Самара: Изд-во СГАУ, 2006. 180 с.
8. Сойфер В.А. и др. Методы компьютерной обработки изображений / 2-е изд., испр. – М.: Физматлит, 2003. 784 с.
9. Франсуа Ш. Глубокое обучение на Python. – СПб.: Питер, 2018. 400 с.
10. Shamir Reuben R. et al. Continuous dice coefficient: A method for evaluating probabilistic segmentations. 2019 / arXiv preprint arXiv:1906.11031.

Константин Олегович Иванов,
канд. техн. наук, доцент,
Артёмий Витальевич Казаринов,
ассистент,

кафедра радиотехнических и медико-биологических систем,
ФГБОУ ВО «Поволжский государственный
технологический университет»,
Василий Николаевич Дубровин,
д-р мед. наук, профессор,
зав. урологическим отделением,
ГБУ РМЭ «Республиканская клиническая больница»,
Алексей Аркадьевич Рожнецов,
д-р техн. наук, профессор,
проректор по развитию университетского комплекса,
Алексей Александрович Баев,
канд. техн. наук, доцент, зав. кафедрой,
Алексей Олегович Евдокимов,
канд. техн. наук, доцент,
кафедра радиотехнических и медико-биологических систем,
ФГБОУ ВО «Поволжский государственный
технологический университет»,
г. Йошкар-Ола,
e-mail: kazarinov_av@mail.ru

Таблица 1

Точность различных конфигураций сети U-Net при сегментации тканей почки

Номер конфигурации сети	Кол-во слоев	Кол-во операций свертки для каждого слоя	Результат обучения (коэффициент Дайса), %
1	6	96, 256, 384, 384, 256, 96	96,5
2	6	32, 64, 128, 128, 64, 32	97,1
3	10	32, 64, 128, 256, 512, 512, 256, 128, 64, 32	98,7