

СЕГМЕНТАЦИЯ НОВООБРАЗОВАНИЙ ПЕЧЕНИ ПО ДАННЫМ КОМПЬЮТЕРНОЙ ТОМОГРАФИИ НА ОСНОВЕ СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ТИПА ALEXNET

А.Н. Корабельников¹, А.В. Колсанов², Р.Н. Косарев³, А.В. Никоноров¹

¹ Самарский государственный аэрокосмический университет имени академика С.П. Королёва (национальный исследовательский университет) (СГАУ), Самара, Россия,

² Самарский государственный медицинский университет, Самара, Россия,

³ Общество с ограниченной ответственностью Самарская компания "МЕДЭКС" (ООО "МЕДЭКС"), Самара, Россия

Сегментация анатомических структур по данным компьютерной томографии – КТ, является ключевым этапом медицинской визуализации и компьютерной диагностики. Новообразования один из тех типов внутренних структур, для которых задача автоматической сегментации на сегодня не имеет решения, полностью удовлетворяющего по качеству. Это обусловлено большой вариабельностью плотности новообразований и невозможностью использования априорных сведений об анатомии.

В настоящей работе предложен метод сегментации новообразований печени на основе свёрточных нейронных сетей (СНС). Обучение и тестирование проведено по набору КТ исследований с предварительно сегментированными новообразованиями. В результате кроссвалидации, получено среднее значение ошибки VOE 17,3%. Рассмотрены алгоритмы пред- и постобработки, обеспечивающие повышение точности и производительности процедур сегментации на основе СНС. В частности, получено ускорение процедуры сегментации в 6 раз при незначительном снижении качества.

Ключевые слова: глубинное обучение, свёрточные нейронные сети, компьютерная томография, сегментация, новообразования печени, автоматизированная диагностика.

Введение

Сегментация анатомических структур по данным компьютерной томографии – КТ, является ключевым этапом медицинской визуализации и компьютерной диагностики (CAD, computer-aided diagnosis). Сегментация новообразований печени необходима при диагностике и планировании вариантов лечения рака печени, таких как: резекция опухоли, радиотерапия под визуальным контролем, радиочастотная абляция и т.д. Цель данной работы – исследование метода сегментации новообразований печени на основе свёрточных нейронных сетей (СНС).

В работах [1-4] выполняется сегментация различными методами: методом водораздела, пороговыми методами, методом разделения графа и классификацией с выбором признаков. В работе [5] применены методы глубинного обучения для сегментации поджелудочной железы.

Сегментация изображений - это процесс присвоения таких меток каждому пикселю изображения, что пиксели с одинаковыми метками имеют общие визуальные характеристики [6]. Таким образом, изображение разделяется на 2 сегмента: новообразования и здоровые ткани печени.

Мотивация исследований и основной вклад

В отличие от сегментации органов, задача сегментации новообразований существенно осложнена тем, что расположение, форма и плотность новообразований в печени сильно

меняются от пациента к пациенту, эти факторы не позволяют использовать априорную информацию об анатомической форме, существенно повышающую точность сегментации в других случаях [7].

Критерием качества сегментации используются различные метрики, и не существует единого стандарта [8,9]. В работе будут использованы метрика VOE (Volume Overlapping Error, англ. ошибка наложения).

В настоящей работе рассмотрен разработанный метод сегментации новообразований на основе свёрточных нейронных сетей. Предложены процедуры пред- и постобработки направленные на повышение скорости обработки и повышение точности сегментации. Также показано, что дополнительное разделение участков поражённой ткани на подклассы позволяет существенно повысить качество сегментации по сравнению с двухклассовым разделением здоровая/поражённая ткань.

1. Архитектура и обучение свёрточной нейронной сети для задачи сегментации

Постановка задачи

Сегментация строится посредством отнесения каждого вокселя изображения к классу поражённой или здоровой ткани. На вход классификатора подается 2D окрестность вокселя, взятая в аксиальной проекции, а на выходе получается класс, к которому относится воксел. В качестве классификатора в настоящей работе будет использоваться СНС. Классификация выполняется для всех вокселей региона интереса соответствующего печени, сегментация которой предполагается предварительно построенной.

Свёрточные нейронные сети

Свёрточные нейронные сети (СНС), предложенные в работе [10] являются развитием подхода многослойных нейронных сетей с обратным распространением ошибки (НС). Слои СНС состоят из нейронов с нелинейной активационной функцией и наборов весов. Обучение сети состоит в подстройке весов слоев и других параметров сети таким образом, чтобы минимизировать ошибку классификации на обучающей выборке. Важно, что, все методы, разработанные для обыкновенных НС, остаются применимы.

СНС условно можно разделить на 2 составляющих: свёрточную и полносвязную. Свёрточная часть отвечает за получение признаков, а полносвязная – реализует классификатор на основе полученных признаков. Таки образом СНС позволяют в дополнение к классификации решить задачу формирования признаков оптимальных для представленной обучающей выборки.

Нейронные сети получают на вход вектор значений и преобразуют его с помощью последовательности скрытых слоёв. Каждый скрытый слой составлен из множества нейронов, где каждый нейрон соединён со всеми нейронами предыдущего слоя, причём нейроны в слое полностью независимы и не используют общих соединений. Последний полносвязный слой, называется «выходным слоем», и в случае классификации представляет оценки вероятностей классов [11].

*Архитектура сети***Табл. 1.** Архитектура сети, созданная на основе AlexNet.

№	Тип (размер ядра, шаг, дополнение)	Выходной размер	Глубина
0	Вход	64x64	1
1	Convolution (11,4,0)	14x14	64
2	ReLU	14x14	64
3	LRN	14x14	64
4	Pooling (3,2)	7x7	64
5	Convolution (5,1,2)	7x7	192
6	ReLU	7x7	192
7	LRN	7x7	192
8	Pooling (3,2)	3x3	192
9	Convolution (3,1,1)	3x3	384
10	ReLU	3x3	384
11	Convolution (3,1,1)	3x3	256
12	ReLU	3x3	256
13	Convolution (3,1,1)	3x3	256
14	ReLU	3x3	256
15	Pooling (3,2)	1x1	256
16	Full Connected	1x1	4096
17	Dropout, доля 0,5	1x1	4096
18	Full Connected	1x1	4096
19	ReLU	1x1	4096
20	Dropout, доля 0,5	1x1	4096
21	Full Connected	1x1	2 (3)
22	Prob	1x1	2 (3)

В работе [12] представлена сеть AlexNet, предназначенная для семантической классификации изображений. Данная сеть была модифицирована для принятия на вход изображений в градациях серого и выдачи 2 (или 3) классов на выходе.

В таблице 1 описаны все слои с параметрами в порядке их следования в сети. Особенностью свёрточных (Convolution) слоёв является то, что они снижают пространственную размерность изображения, но увеличивают глубину (количество экземпляров слоя с различными коэффициентами). Pooling-слой выполняет операцию взятия максимума по заданному окну, т.о. на выходе будет уменьшенное изображение. Стандартный слой ReLU выполняет кусочно-линейное преобразование $\max(x, 0)$. Слой LRN(Local Response Normalization) выполняет нормировку по входной области (по умолчанию по всему каналу глубины). Full Connected слой выполняет скалярное произведение, принимая на вход вектор и, возвращая скаляр. Dropout слой обнуляет выходы части нейронов скрытого слоя на этапе обучения, т.о. он сдерживает сеть от переобучения [11, 12].

Программная реализация СНС

Существует достаточно большое количество библиотек и пакетов реализующих СНС. Один из наиболее перспективных - это пакет Caffe разработанный в BVLC и распространяемый под лицензией BSD 2 [9, 13].

Выбор Caffe обусловлен следующими причинами:

- декларативное описание архитектуры сети и процедуры обучения;
- репозиторий моделей, де факто ставших стандартом в глубинном обучении [13];
- гибкость архитектур, исполнение как на CPU, так и на GPU;
- открытый исходный код (C++) и поддержка сообщества;
- API к языкам python и Matlab;
- одна из самых быстродействующих реализаций СНС на текущий момент [9].

Определение эффекта переобучения СНС

Как известно, методы машинного обучения обладают таким неприятным свойством как переобучение. Переобучение, переподгонка (overtraining, overfitting) - нежелательное явление, при котором ошибка обучения при увеличении количества итераций монотонно уменьшается, тогда как ошибка обобщения снижается до определенного предела, а затем снова начинает расти [10].

На рисунке 1 показаны ошибки на обучающей и контрольной выборке при двухклассовом подходе до постобработки.

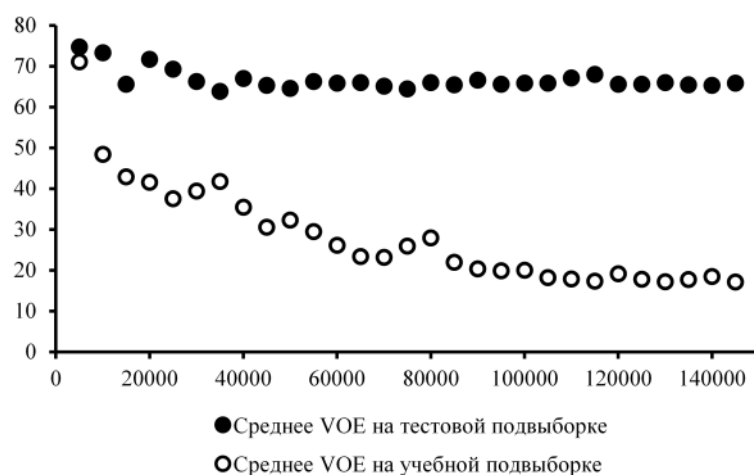


Рис.1. Зависимость VOE на обучающей и контрольной выборке от итерации обучения

Очевидно, что ошибка на тестовой подвыборке достигает минимума на 35 тыс. итераций. Т.о. дальнейшее обучение приводит не к улучшению обобщающей способности, а к лучшей аппроксимации учебных данных.

В [12] указывается, что СНС эффектом переобучения не обладают. По рисунку 1 видно, что эффект наблюдается частично: при уменьшении ошибки на обучающей выборке, ошибка на тестовой выборке фиксируется и больше не увеличивается.

2. Алгоритмы сегментации

Метод сегментации приставляет из себя 2 стадии: подготовительную стадию – обучение СНС и собственно сегментацию с применением СНС. Сегментация состоит из следующих шагов:

1. Предобработка (отображение в диапазон $[0,255]$);
2. Классификация;
3. Постобработка (размытие, порог).

Предобработка

Исходные данные КТ в формате DICOM имеют размер $512 \times 512 \times N$, где N число аксиальных срезов, которое в общем случае может быть любым. Каждый воксел КТ имеет формат двухбайтового целого со знаком (int16) и хранит значение рентгенологической плотности по шкале Хаунсфилда в интервале от -2000 до 2000.

Диапазон плотностей исследуемых тканей $[-60; 240]$. При классификации выполняется преобразование из int16 к uint8 с учетом указанного диапазона.

Исследования имеют разные физические разрешения – линейные размеры воксела. Опыты показали, что приведение изображения к одному линейному размеру (0,78x0,78) повышают точность обучения.

Для обучения из DICOM были извлечены изображения с соответствующими им метками классов, размеров 64×64 . Всего из базы было извлечено порядка 4 миллионов изображений. В обучение примеры для классов взяты в соотношении 1:1.

Предварительное разделение на 3 класса

Исходные данные для обучения состояли из двухклассовой разметки здоровая/пораженная ткань. В результате экспериментов было замечено, что класс пораженной (опухолевой) ткани обладает большой вариативностью, что существенно снижает точность классификации. Было выполнено разделение на три класса, с разделением класса пораженной ткани на два. Пример такого разделения приведен на рисунке 2. (выделено светлым и темным красным цветом).




Рис.2. Разделение класса «новообразование» на 2 класса

Улучшение производительности

Эксперименты на GPU NVidia Tesla K20m показали среднее время исполнения на всем объеме печени в среднем 15-20 минут. Поэтому для улучшения производительности была использована группировка, так, чтобы классифицировался только 1 центральный пиксел из группы. На рисунке 3 представлена зависимость качества и времени от линейного размера группировки.




Рис.3. Зависимость качества сегментации от размера группировки

Как видно из рисунка наилучшее соотношение качество/время достигается при группировке 3x3. При этом достигается ускорение в 6 раз по сравнению с классификацией без группировки, и ошибка VOE увеличивается на 0,6%

Постобработка

Задача сегментации на основе СНС решается для каждого пиксела независимо, что приводит к разрывам и зашумленности в результирующей сегментации. Пример приведенный на рисунке 4 демонстрирует, что сегментация получается негладкая, и присутствуют одиночные ложные срабатывания.




Рис.4. Постобработка. Красным выделен полученный результат, зеленым – эталонный. а) до постобработки, б) после постобработки

После классификации для сглаживания и удаления ложных срабатываний к меткам классов применяются 2 фильтра: размытие по Гауссу с $\sigma=4$ и пороговая обработка.

3. Результаты экспериментов

Методика проведения эксперимента

Для обучения и проведения экспериментов использовались исследования (КТ) из базы СамГМУ (5 исследований).

Для оценки обобщающей способности алгоритмов машинного обучения используются разные методики перекрёстной проверки.

Leave-one-out (LOO) – это методика оценивания качества, состоящая в том, что можно один прецедент оставить в стороне и обучить алгоритм на всех за исключением одного [14]. Минусом LOO является вычислительная неэффективность.

В противовес LOO существует методы, основанный на случайных разбиениях. Можно разбить учебную выборку таким образом, чтобы одна часть, случайная подвыборка не

участвовала в обучении и стала контрольной. Так как целью данного метода является устранение вычислительной неэффективности, много раз процедура не может быть повторена. Таким образом, может случиться, что одни прецеденты участвовали в контроле чаще других, и оценка может оказаться смещенной.

QFold-CV – это компромисс между LOO и случайными разбиениями. Выборка некоторым (возможно случайным) образом разбивается на n непересекающихся блоков одинаковой (или почти одинаковой) длины, q случайных блоков по очереди становятся контрольной подвыборкой, при этом обучение производится по всем остальным блокам [15].

Результаты

В данной работе использовался метод Q-Fold-CV: выборка разбивалась на 4 части. В таблице 2 представлены результаты по всем исследованиям после процедуры постобработки. Заметим, что при 3 классах результат в среднем лучше на 39% VOE.

Таблица 2. Результаты перекрёстной проверки

№ исследования	2-х классовый подход, VOE	3-х классовый подход, VOE
1	58,56%	15,17%
2	35,69%	30,56%
3	46,62%	17,04%
4	59,08%	14,46%
5	80,32%	9,42%
Среднее	56,06%	17,33%

Заключение

СНС показывают возможность сегментации новообразований печени наравне с другими методами. В настоящей работе показано, что архитектура СНС типа AlexNet [11] применима для решения задачи сегментации новообразований. Проанализировано качество метода при пред- и постобработке, обучении, зафиксирован факт частичного переобучения и оптимальное число итераций, проведена оптимизация скорости исполнения. Предложенный алгоритм постобработки позволяет ускорить сегментацию в 6 раз при незначительном снижении качества.

Дополнительное разбиение на классы позволяет существенно повысить качество, при этом достигается точность, продемонстрированная в аналогичных работах [6]. Объектом дальнейших исследований может быть создание методов автоматического разделения классов на подклассы, например кластеризация.

Литература

1. Pham, A. A comparison of texture models for automatic liver segmentation / Mailan Pham, Ruchaneevan Susomboon, Tim Disney, Daniela Raicu, Jacob Furst // Proc. SPIE. – 2007. - Vol. 6512.
2. Jimenez, O. Texture classification of anatomical structures using a context-free machine learning approach / Jiménez del Toro, Oscar A., Foncubierta-Rodríguez, Antonio, Depeursinge, Adrien, Müller, Henning // Proc. SPIE. – 2015. – Vol. 9114.
3. Depeursinge, A. Three-dimensional solid texture analysis in biomedical imaging: Review and opportunities / Adrien Depeursinge, Antonio Foncubierta-Rodríguez, Dimitri Van De Ville, Henning Müller // Medical Image Analysis. – 2014. - Vol. 18. – P. 176-196. – ISSN 1361-8415.

4. Гильманов, Т.А. Сравнение методов сегментации в задаче распознавания дорожных знаков / Т. А. Гильманов // Science Time. – 2015. - № 1(13). – С. 86-91.
5. Holger, R. Deep convolutional networks for pancreas segmentation in CT imaging / Holger Roth, Amal Farag, Le Lu, B. Turkbey, Ronald M. Summers// CoRR. – 2015.- Vol. 1504.03967.
6. Vivanti, R. Automatic liver tumor segmentation in follow-up CT studies using Convolutional Neural Networks / R. Vivanti // Proc. Patch-Based Methods in Medical Image Processing Workshop, MICCAI. – 2015.
7. Qi, Y. Semi-automatic Segmentation of Liver Tumors from CT SCans Using Bayesian Rule-based 3D / Yingyi Qi, Wei Xiong, Wee Kheng Leow, Qi Tian, Jiayin Zhou, Thazin Han, Sudhakar K Venkatesh, Shih-chang Wang // The MIDAS Journal. – 2008.
8. Пакет для глубокого обучения [Электронный ресурс]. – URL: <http://caffe.berkeleyvision.org> (дата обращения 01.02.2016).
9. LeCun, Y. Convolutional networks for images, speech, and time series / LeCun, Yann., Yoshua Bengio // The handbook of brain theory and neural networks. – 1995. – Vol. 3361.10.
10. Hastie, T. The Elements of Statistical Learning, 2nd edition / T. Hastie., R. Tibshirani, J. Friedman // Springer. – 2009. – P. 533
11. Krizhevsky, A. Imagenet classification with deep convolutional neural networks / Krizhevsky A, Sutskever I, Hinton GE // Advances in neural information processing systems. – 2012. -P. 1097-1105
12. Srivastava, N. Dropout: A simple way to prevent neural networks from overfitting / Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. // The Journal of Machine Learning Research. – 2014. – Vol 15(1). - P. 1929-1958.
13. Набор обученных моделей Caffe [Электронный ресурс]. – URL: http://caffe.berkeleyvision.org/model_zoo.html (дата обращения 01.02.2016).
14. Gelfand, A.E. Model determination using sampling-based methods /Gelfand, A.E // Markov chain Monte Carlo in practice. – 1996. - P.145-161.
15. Kohavi, R. A study of cross-validation and bootstrap for accuracy estimation and model selection / Kohavi, R // Ijcai. – 1995. – Vol 14.2. - P. 1137-1145.