

Сверточная нейронная сеть для обнаружения патологий на изображениях МРТ головного мозга

Ю.Д. Агафонова¹, А.В. Гайдель^{1,2}, П.М. Зельтер³, А.В. Капишников³

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

²Институт систем обработки изображений РАН - филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

³Самарский государственный медицинский университет, Чапаевская 89, Самара, Россия, 443099

Аннотация. В наши дни в медицине существует проблема, связанная с постановкой достоверного диагноза в кратчайшие сроки, особенно в случаях диагностики новообразований. В статье говорится об исследовании метода диагностики заболеваний головного мозга по изображениям магнитно-резонансной томографии. Описанный метод основан на глубоком обучении. В работе предложен новый подход к решению задач классификации, была сформирована оптимальная структура сверточной нейронной сети. В результате экспериментальной деятельности, было произведено исследование основополагающих характеристик сверточной нейронной сети. Благодаря использованию данной архитектуры сверточной нейронной сети 95% изображений из контрольной выборки были классифицированы правильно. Кроме того, результаты могут быть использованы в качестве промежуточного результата для дальнейшего анализа изображений.

1. Введение

В медицине существует проблема постановки достоверного диагноза в кратчайшие сроки в связи с нарастающим объемом медицинских исследований. Особенно остро данная проблема ощущается в случаях диагностики различных новообразований. Решить данную проблему может помочь представленный метод. Данный метод способен классифицировать значительное число снимков магнитно-резонансной томографии (МРТ) головного мозга на два класса. К первому классу относятся магнитно-резонансные томограммы, на которых какие-либо новообразования отсутствуют. Ко второму классу относятся снимки, на которых присутствует какое-либо новообразование. Снимки только из второго класса требуют внимание врачей. Именно это отличие может ускорить процесс диагностики различных новообразований.

Алгоритм для решения подобной задачи с помощью классификатора представлен в [1]. Описанный классификатор был основан на применении ансамбля решающих деревьев [2], в качестве входных данных был использован набор, состоящий из 98 изображений первого класса и 98 изображений второго класса. Все изображения имели размеры 512×512 отсчетов. Равное соотношение классов было сделано для максимальной объективности полученных результатов. Приведенный алгоритм относил каждый отсчет изображения к области патологических изменений либо к фону, так что фактически решал задачу классификации

каждого отсчёта. Однако существенным недостатком описанного метода является объемная подготовка входных данных для достижения высоких результатов классификации.

В основу данной статьи легла идея достичь более высоких показателей классификации на том же наборе входных данных, но на основе иного, более современного метода. Чтобы показать эффективность приведенного метода над алгоритмом, основанным на ансамбле решающих деревьев, в данном исследовании будут использованы следующие оценки качества:

– точность

$$J_P = N_{TP} / (N_{TP} + N_{FP}),$$

– полнота

$$J_R = N_{TP} / (N_{TP} + N_{FN}),$$

– F-мера Ван Ризбергена

$$F_1 = 2 J_P J_R / (J_P + J_R),$$

– специфичность

$$J_S = N_{TN} / (N_{TN} + N_{FP}),$$

– достоверность

$$J_A = (N_{TP} + N_{TN}) / (N_{TP} + N_{TN} + N_{FP} + N_{FN}), \quad (1)$$

где N_{TP} – число верно определённых отсчётов, относящихся к области патологических изменений, N_{TN} – число верно определённых отсчётов, относящихся к фону, N_{FP} – число отсчётов фона, ошибочно отнесённых к области патологических изменений, а N_{FN} – число отсчётов, относящихся к области патологических изменений, но ошибочно отнесённых к фону.

Источниками материалов для исследований выступали архив CENTRAL, поддерживаемый Washington University School of Medicine, на платформе XNAT [3] и The Cancer Imaging Archive [4], созданный федеральным исследовательским центром Frederick National Laboratory for Cancer Research. Из патологий на изображениях присутствовали менингиомы и глиобластомы.

В таблице 1 показаны метрики алгоритма, основанного на ансамбле решающих деревьев, размерность которых обозначим отправной. В качестве признаков использовались факторы формы объектов, выделенных на изображении с помощью адаптивной пороговой обработки. F-мера Ван Ризбергена была обозначена основной метрикой для оценки качества алгоритма. Именно по этой метрике на протяжении всей работы будет произведено сравнение эффективности различных изменений на качество классификации.

Таблица 1. Результаты исследования работы классификатора.

Критерий	Снимки МРТ с новообразованиями	
	J	Ошибка
J_P	0.81	0.19
J_R	0.97	0.03
F_1	0.88	0.12
J_S	0.77	0.23
J_A	0.87	0.13

2. Сверточная нейронная сеть

В настоящее время для решения задач классификации распространенным методом является использование сверточных нейронных сетей. Впервые они были описаны ещё в прошлом столетии [5]. Такой подход является эффективным для решения задач широкого спектра. Но, для достижения максимальной эффективности, необходимо учесть множество факторов, влияющих на обучение нейронных систем [6]. В данной работе будут рассмотрены

проведенные экспериментальные исследования по определению оптимальной архитектуры сверточной нейронной сети для решения поставленной задачи. Изначальная архитектура схожа по архитектуре с AlexNet [7].

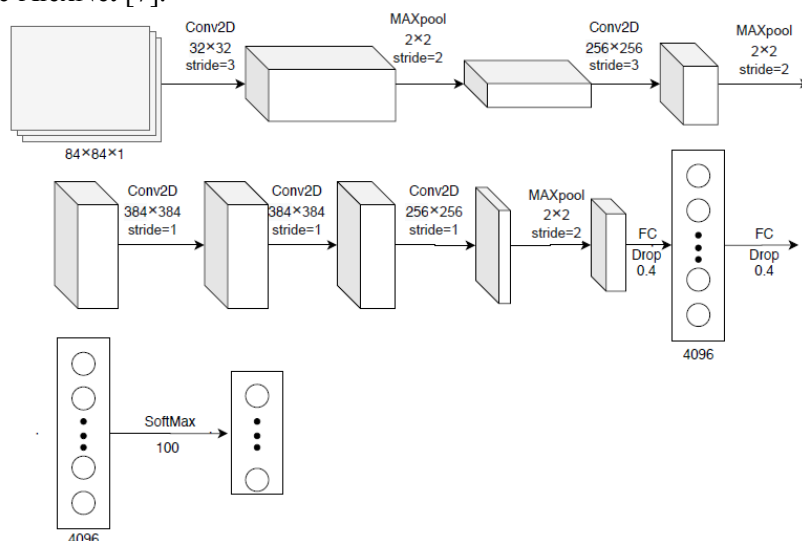


Рисунок 1. Архитектура сверточной нейронной сети.

Как показано на рисунке 1, изначально сеть состоит из 5 сверточных слоев, слоев субдискретизации и полносвязных слоев. Входные изображения были уменьшены с 512×512 отсчетов до 72×72 отсчетов. Обучение длилось на протяжении 120 эпох. На слоях свертки и полносвязных слоях (за исключением последнего полносвязного слоя) была использована функция активации ReLu:

$$f_{\text{ReLU}}(x) = \max(x, 0).$$

Для оценки потерь была использована бинарная кросс – энтропия (2), где N – количество изображений в выборке, y_i – класс i -го изображения, p_i – значение, выданное нейронной сетью для i -го изображения.

$$H_p = -\frac{1}{N} \sum_{i=1}^N (y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)). \quad (2)$$

В таблице 2 приведены показатели эффективности (1) для сверточной нейронной сети, которую обозначили исходной. В сравнении с таблицей 1, F-мера Ван Ризбергера выше на 3%, однако это изменение не столь существенно отражается на качестве классификации.

Для оценки показателей эффективности также был использован график ROC – curve [8] и график Precision-Recall curve [9]. Графики приведены на рисунке 2(а) и рисунке 2(б) соответственно. О показательности оценки эффективности классификации в данных графиках упоминается в [10]. Принцип Precision-Recall curve основан на средней точности:

$$AP = \sum_n (R_n - R_{n-1}) P_n,$$

где R_n и P_n точность и полнота на пороге n .

Таблица 2. Результаты исследования работы исходной сети.

Критерий	Снимки МРТ с новообразованиями	
	J	Ошибка
J_p	0.83	0.17
J_R	1.00	0.00
F_I	0.90	0.10
J_S	0.71	0.29
J_A	0.88	0.12




Рисунок 2. Изменение параметров оценки классификации в процессе обучения сверточной нейронной сети на графике ROC – curve (а) и графике зависимости Precision-Recall curve (б).

3. Исследование эффективности алгоритма классификации, основанного на сверточной нейронной сети

3.1 Влияние размера входного изображения на эффективность алгоритма

Для улучшения оценок качества (1) было принято решение последовательно исследовать влияние различных характеристик архитектуры сверточной нейронной сети на эффективность. Первым исследованием стало определение влияния размера входного изображения. Как говорилось в разделе 2, изначально изображение имело размеры 512×512 отсчетов, и было уменьшено до 72×72 отсчетов. Чтобы не было существенных изменений в скорости работы сверточной нейронной сети, исследование производилось на изображениях МРТ головного мозга следующих размеров: 32×32 , 40×40 , 48×48 , 56×56 , 64×64 , 72×72 , 84×84 , 92×92 . Следует отметить, что исходный размер изображений остался прежним, 512×512 отсчетов, изменялся размер непосредственно входного изображения.

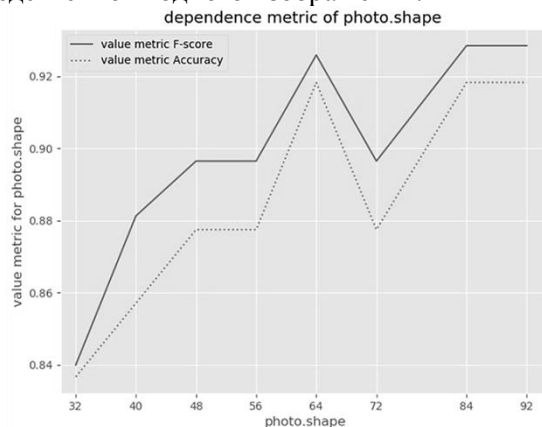


Рисунок 3. Зависимость F-меры Ван Ризбергера и достоверности от изменения параметров размера входного изображения для сверточной нейронной сети.

На рисунке 3 представлен график зависимости F-меры Ван Ризбергера и достоверности от размера входного изображения. Как видно на графике, принимает наибольшее значение при размерах входного изображения в 84×84 и 92×92 отсчетов. Размер 92×92 отсчетов был принят как наиболее благоприятный размер для входного изображения в решении данной задачи.

Вид оценки качества алгоритма с изменением размера входного изображения представлен в таблице 3.

3.2 Влияние изменения сверточных слоев на эффективность алгоритма

Следующим этапом работы стало исследование влияния сверточных слоев нейронной сети на работу алгоритма. На рисунке 4 показана величина F-меры Ван Ризбергера и достоверности в зависимости от исследования. По оси ОХ расположены номера экспериментов (от 1 до 5). В

эксперименте №1 была заменена функция активации второго и третьего слоя. В эксперименте №2 и №3 был увеличен фильтр третьего слоя с 384 до 512 и второго слоя с 256 до 384, соответственно. Также был добавлен дополнительный, шестой сверточный слой (между четвертым и пятым слоем) в эксперименте № 5. Этот слой имел ядро свертки 3×3 отсчета и фильтр, равный 256. В эксперименте № 4 наоборот, было всего четыре сверточных слоя. Слой между третьим и пятым сверточным слоем из исходной архитектуры был удален.

Таблица 3. Результаты исследования влияния изменения размера входного изображения на эффективность алгоритма.

Критерий	Снимки МРТ с новообразованиями	
	J	Ошибка
J_P	0.89	0.17
J_R	0.96	0.00
F_I	0.92	0.10
J_S	0.86	0.29
J_A	0.92	0.12

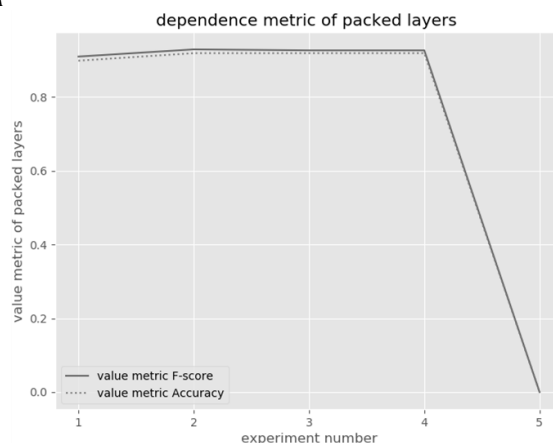


Рисунок 4. Влияние изменения сверточных слоев на эффективность алгоритма.

Как показано на рисунке 4, данные эксперименты не принесли положительную динамику в улучшении качества классификации, а наоборот, ухудшили достигнутый результат. Более того, в эксперименте № 5 произошло переобучение [11].

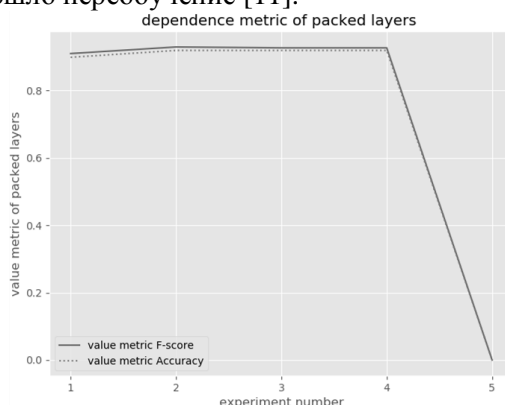


Рисунок 4. Влияние изменения сверточных слоев на эффективность алгоритма.

3.3 Влияние численных значений ядер свертки на эффективность алгоритма

Заключительным этапом в работе стало исследование влияния численных значений ядер свертки сверточных слоев сети на результаты классификации. Изначально, у второго слоя,

согласно изначальной архитектуре сверточной нейронной сети, было ядро 11×11 отсчетов. В качестве экспериментов были взяты ядра свертки 9×9 , 7×7 , 13×13 отсчетов. Результаты исследования указаны в таблице 4.

Таблица 4. Результаты влияния изменений ядер свертки.

Критерий	Ядро 9×9		Ядро 7×7		Ядро 13×13	
	J	Ошибка	J	Ошибка	J	Ошибка
J_P	0.93	0.07	0.92	0.08	0.92	0.08
J_R	0.96	0.04	0.92	0.08	0.85	0.15
F_I	0.95	0.05	0.92	0.08	0.88	0.12
J_S	0.90	0.10	0.90	0.10	0.90	0.10
J_A	0.94	0.06	0.92	0.08	0.87	0.13

Таким образом, как видно из таблицы, ядро свертки 9×9 отсчетов является наиболее эффективным для решения задач классификации для данной архитектуры сверточной нейронной сети. Для оценки потерь конечной модели была использована бинарная кросс – энтропия (2). Оценка производилась после каждой эпохи, это можно увидеть на рисунке 5.




Рисунок 5. Эффективность обучения нейронной сети в зависимости от номера эпохи (train_acc и val_acc – значения достоверности (1) для обучающей и для контрольной выборки, train_loss и val_loss – значения функции потерь (2) для обучающей и для контрольной выборки).

4. Заключение

В работе исследовались различные методы улучшения классификации изображений МРТ головного мозга, основанные на сверточной нейронной сети. Была разработана оригинальная архитектура сверточной нейронной сети, дающая максимальную эффективность для решения данной задачи.

В ходе экспериментальных исследований на наборе изображений МРТ средняя оценка качества классификации алгоритма стала выше, чем иного метода, основанного на ансамбле решающих деревьев. При этом необходимость в объемной подготовке входных данных отпала, что может дать прирост в скорости обработки изображений МРТ при применении на практике. Величина F-меры Ван Ризбергера составила 95%, а вероятность ошибочной классификации оказалась равной 6%. Это показывает, что точность классификации, по сравнению с методом, описанным в разделе 1, стала выше. Таким образом, можно рекомендовать использовать полученную архитектуру сверточной нейронной сети для задач распознавания патологий на изображениях МРТ головного мозга.

Данные результаты исследования могут быть использованы при создании информационной системы диагностики патологий различного рода по изображениям МРТ головного мозга человека.

5. Благодарности

Работа выполнена при поддержке грантов РФФИ № 19-29-01235 мк и № 19-29-01135 мк, экспериментальные исследования – в рамках госзадания ИСОИ РАН – филиала ФНИЦ «Кристаллография и Фотоника» РАН (соглашение № 007-ГЗ/Ч3363/26).

6. Литература

- [1] Agafonova, J.D. Localization of the area of pathological changes in the images of brain MRIs / J.D. Agafonova, A.V. Gaidel – Samara: Advanced Information Technology (AIT). – 2019. – Vol. 362-365.
- [2] Breiman, L. Random Forests / L. Breiman // Machine Learning. – 2001. – Vol. 45(1). – P. 5-32.
- [3] Herrick, R. XNAT Central: Open sourcing imaging research data / R. Herrick, W. Horton, T. Olsen, M. McKay, K.A. Archie, D.S. Marcus // Neuroimage. – 2016. – Vol. 124(Pt B). – P. 1093-1096.
- [4] Clark, K. The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository / K. Clark, B. Vendt, K. Smith, J. Freymann, J. Kirby, P. Koppel, S. Moore, S. Phillips, D. Maffitt, M. Pringle, L. Tarbox, F. Prior // Journal of Digital Imaging. – 2013. – Vol. 26(6). – P. 1045-1057.
- [5] LeCun, Y. Gradient-based learning applied to document recognition / Y. LeCun, L. Bottou, Y. Bengio, P. Haffner // Proceedings of the IEEE. – 1998. – Vol. 86(11). – P. 2278-2324.
- [6] He, K. Convolutional neural networks at constrained time cost / K. He, J. Sun // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015. – P. 5353-5360.
- [7] Krizhevsky, A. ImageNet Classification with Deep Convolutional Neural Networks / A. Krizhevsky, I. Sutskever, G.E. Hinton // Communications of the ACM. – 2017. – Vol. 60(6). – P. 84-90.
- [8] Fawcett, T. An introduction to ROC analysis // Pattern Recognition Letters. – 2006. – Vol. 27(8). – P. 861-874.
- [9] Davis, J. The Relationship Between Precision-Recall and ROC Curves / J. Davis, M. Goadrich // ICML, 2006.
- [10] Saito, T. The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets / T. Saito, M. Rehmsmeier // PLoS ONE. – 2015. – Vol. 10(3). – P. e0118432.
- [11] Vapnik, V.N. Statistical learning theory – N.Y.: John Wiley & Sons, Inc., 1998.

Convolutional neural network for detection of pathological changes in MR images of the brain

Yu.D. Agafonova¹, A.V. Gaidel^{1,2}, P.M. Zelter³, A.V. Kapishnikov³

¹Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

²Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

³Samara State Medical University, Chapayevskaya 89, Samara, Russia, 443099

Abstract. At the present day, the problem is subsisting associated with a reliable diagnosis as soon as possible, especially in medicine in cases of diagnosis of neoplasms. The article discusses research method for the diagnosis of brain diseases in magnetic-resonance tomography images, based on deep learning. This paper presents a novel approach to solutions pattern classification, was formed the optimal architecture convolutional neural network. As a result of experimental studies, was undertake a study major characteristic of convolutional neural network. Through the use of this neural network architecture 95 % the images from the validation set were classified correctly. In addition, the results can be used as an intermediate result for further images analysis.