

ИССЛЕДОВАНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ОБРАБОТКИ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ И КЛАССИФИКАЦИИ ОПУХОЛЕЙ МОЛОЧНОЙ ЖЕЛЕЗЫ

Ю.П. Зайченко, Г. Гамидов

Резюме: Рассмотрена проблема анализа медицинских изображений и классификации опухолей молочной железы. Для ее решения предлагается применение различных сверточных нейронных сетей CNN VGG16, VGG19, ResNet50 v 2, Inception и Xception. Экспериментальные исследования предложенной CNN на стандартном наборе данных BreakHis проводились в задачах бинарной и мультиклассовой классификации. Было проведено сравнение с известными результатами и оценена эффективность различных CNN. Лучший класс CNN для этой задачи был определен с максимальной точностью.

Key words: breast cancer classification, medical diagnostics, CNN, accuracy

ITHEA Keywords: 1. Computing methodologies 12. Artificial intelligence, 16.5. Model development

DOI: <https://doi.org/10.54521/ijita28-02-p05>

Введение

Рак молочной железы является наиболее распространенным раком у женщин как в развитых, так и в менее развитых странах. Согласно статистике 2019 заболеваемость раком молочной железы среди всех видов рака составляет 11,6%, что приводит к 6,5% смертельных случаев во всем [Siegel, 2019]. Также по данным «ГЛОБОКАН» заболеваемость раком молочной железы увеличится с двух миллионов пациентов в 2018 до более, чем трех миллионов в 2046, показав рост на 46% [Siegel, 2019]. Вследствие его неизлечимого характера и длительного процесса болезни

рак молочной железы является бременем как для пациентов, так и для лиц, ухаживающих за больными [Grunfeld, 2004], [Kale and Carroll,2016], <https://costsofcare.org/the-costs-of-breast-cancer-in-the-u-s>.

Большое значение имеет ранняя диагностика раковых заболеваний молочной железы, может также помочь вовремя диагностировать опухоли и значительно снизить риски заболеваемости данной болезнью. Для диагностирования онкологических заболеваний, онкологи используют медицинские изображения, полученные с помощью таких методов как компьютерная томография, магнитно-резонансная томография и рентгенологические исследования на протяжении многих лет [Zhang,2013]. Эти системы доказали свою эффективность для диагностики многих видов рака, но некоторые разновидности рака нельзя достоверно диагностировать с помощью этих методов.

На данный момент имеется несколько моделей и методов для обнаружения рака молочной железы, которые используют различные алгоритмы обучения. Используя методы и технологии искусственного интеллекта, такие, как нейронные сети и метод опорных векторов в работах [Lakhani, 2012], [Zhang, 2013] была достигнута точность классификации опухолей от 74 до 94% на наборе данных из 92 изображений.

На протяжении многих лет основным средством получения признаков изображений для последующей классификации являлись текстурные дескрипторы. Однако недостаток их использования состоит в отсутствии универсальности, в следствие чего, что для каждого типа изображений необходимо разрабатывать свои дескрипторы. [Doyle, 2008] Другой подход базируется на системах машинного обучения презентациям [Bengio, 2013].

В последнее время уделяют много внимания сверточным нейронным сетям [LeCun , 2015], [Krizhevsky , 2012] .

Их использование для классификации изображений превышает эффективность традиционных методов, основанных на классических методах компьютерного зрения и там, где нет дефицита данных для обучения. С одной стороны для задач анализа медицинских изображений

недостатка данных нет, но с другой стороны, для того чтобы получить качественные и правильно классифицированы наборы данных нужно затратить большое количество времени и квалифицированного персонала. Вот почему найти качественный набор данных с достаточным количеством учебных примеров является большой проблемой.

Для решения проблемы эффективного количества учебных примеров обычно используют методы transfer learning и data augmentation [Singh, et al]. Transfer learning-это метод обучения нейронной сети, когда знания, полученные на одной задаче, используются для решения другой задачи. Методика data augmentation основана на применении геометрических и других преобразований с целью расширения наборов данных и обеспечения устойчивости нейронных сетей.

В работе [Zaychenko, 2018] рассмотрена гибридная сверточная сеть CNN VGG 16, в которой нечеткая нейронная сеть NEFClass используется в качестве классификатора в задачах классификации рака молочной железы.

Представляет интерес исследования эффективности сверточных нейронных сетей различной архитектуры (простых сверточных сетей, VGG16, VGG19, ResNet50 v.2, Inception v.3, Xception) в задачах классификации видов рака молочной железы, сравнение с известными результатами и определение наиболее подходящего типа сверточной сети для решения рассматриваемой проблемы. Полученный результат можно было бы использовать для создания улучшенной нейронной модели для расширения методов экспресс диагностики.

Экспериментальные исследования и их анализ

При выполнении работы использовалась интегрированная среда разработки Microsoft Visual Studio, так как данная среда включает целый ряд инструментальных средств для разработки программных продуктов с использованием большого количества языков программирования для выполнения почти всех доступных платформах [28]. В качестве языка программирования использовался Python версии 3.6.

Для работы с нейронными сетями использовались библиотеки TensorFlow версии 2.1 и Keras [Zacccone, 2017].

С целью изучения эффективности использования сверточных нейронных сетей для бинарной и многокласовой классификации видов рака молочной железы использовался стандартный датасет BreaKHis [Spanhol, 2016] и следующие архитектуры нейронных сетей - простая сверточная сеть, VGG16, VGG19, ResNet50 v 2, Inception и Xception .

Описание набора данных BreaKHis

Для исследования использовался набор данных BreaKHis, специально созданный для оценки эффективности различных подходов и методов для медицинских изображений диагностики опухоли молочной железы [Spanhol, 2016].

Гистопатологическая классификация изображений рака молочной железы (BreakHis) состоит из 9109 микроскопических изображений ткани опухоли молочной железы, собранных в 82 пациентов с использованием различных факторов увеличения масштаба (40X, 100X, 200X и 400X). На сегодняшний день набор данных содержит 2480 доброкачественных и 5429 злокачественных образцов (размером 700x460 пикселей, 3-каналы RGB, 8-битная глубина в каждом канале, формат PNG).

Набор данных BreaKHis разделен на две основные группы: доброкачественные опухоли и злокачественные опухоли. Гистологически доброкачественный - это термин, обозначающий поражения, не соответствует никаким критериям злокачественности - например, заметна клеточная атипия, митоз, нарушения базальных мембран, метастазирование и тому подобное. Как правило, доброкачественные опухоли относительно «невинные», медленно растут и остаются локализованными. Злокачественная опухоль является синонимом рака: поражение может вторгнуться и разрушить соседние структуры (локально инвазионные) и распространиться на отдаленные участки (метастазировать), что повлечет смерть.

В текущей версии образцы, присутствующие в наборе данных, были собраны методом SOB, который также называют частичной мастэктомией или эксцизионной биопсией. Этот тип процедуры, по сравнению с любыми методами игольной биопсии, удаляет больший размер образца ткани и проводится в больнице с общим наркозом. Структура датасета BreaKHis приведена в табл.1

Таблица 1. Результаты классификации FNN NEFClass

Увеличение	Количество доброкачественных образцов	Количество злокачественных образцов	Общее количество
40X	652	1370	1995
100X	644	1437	2081
200X	623	1390	2013
400X	588	1232	1820
Общее количество изображений	2480	5429	7909

Доброкачественные и злокачественные опухоли молочной железы можно сортировать по различным типам в зависимости от того, как клетки опухоли смотрят под микроскопом. Различные типы опухолей молочной железы могут иметь различные прогнозы и результаты лечения. В настоящее время набор данных содержит четыре гистологических отличных типа доброкачественных опухолей молочной железы аденоз (A), фибroadенома (F), филодная опухоль (PT) и канальцевая аденона (TA) и четыре злокачественные опухоли (рак молочной железы): карцинома (DC), дольчатая карцинома (LC), муцинозные карцинома (MC) и папиллярная карцинома (PC).

На рис.1 приведены примеры изображений, полученных при различных увеличениях, используемых в данном датасете.




Рис. 1. Примеры изображений злокачественной опухоли при различных увеличениях.

Выбор архитектуры сверточных нейронных сетей

В работе использовались несколько архитектур сверточных нейронных моделей [Zaccone, 2017]:

Простая сверточная нейронная сеть

VGG16;

VGG19;

ResNet50v2;

Inception;

Xception

В качестве классификатора использовался стек из трех полносвязанных слоев размерами 512, 128, 64, 8 или 1 (в зависимости от способа

классификации - бинарной многоклассовой). После каждого слоя происходила операция dropout с вероятностью 0.5.

Данный выбор архитектуры классификатора основан на предыдущих исследованиях, и оказался наиболее подходящий для классификации изображений данного набора.

В качестве моделей VGG16 / VGG19, ResNet50v2, Inception , Xception использовались готовые реализации библиотеки Keras и использовался оригинальный классификатор. Структура подобной модели приведена в таблице 2.

Таблица 2. Структура модели Xception классификатора

```

Model: " sequential "
Layer (type )          Output Shape Param #
=====
xception ( Model ) ( None , 7, 7, 2048) 20861480
-----
flatten (Flatten ) ( None , 100352) 0
-----
dropout ( Dropout ) ( None , 100352) 0
-----
dense ( Dense ) ( None , 512) 51380736
-----
activation ( Activation ) ( None , 512) 0
dropout_1 ( Dropout ) ( None , 512) 0
-----
dense_1 ( Dense ) ( None , 128) 65664
-----
activation_1 ( Activation ) ( None , 128) 0
-----
dense_2 ( Dense ) ( None , 8) 1032
Total params : 72,308,912.
Trainable params : 72,254,384.
Non-trainable params : 54,528.
    
```

Глубокие сверточные нейронные сети требуют очень большого количества изображений для того, чтобы качественно научить модель. Такой подход позволяет увеличить производительность модели благодаря тому, что модель учится лучше обобщать и таким образом уменьшается переобучение. Популярные наборы данных для классификации изображений вмещают тысячи и миллионы изображений.

Способность модели к обобщению результатов обучения относится к производительности модели и выявляется путем проверки на наборе данных изображений, который модель ранее не видела.

Набор данных BreakHis, который использовался в работе, имеет ограниченный размер. Так в наборе можно найти 2480 изображений доброкачественных опухолей, и 5429 изображений злокачественных опухолей. Если анализировать количество по типу заболевания может изображений оказывается еще меньше.

Таблица 3. Распределение количества изображений в зависимости от типа заболевания и кратности

заболевания	40x	100x	200x	400x	всего
Adenosis	114	113	111	106	444
Fibroadenoma	253	260	264	237	1014
Phyllodes tumor	109	121	108	115	453
Tubular adenoma	149	150	140	130	569
Ductal carcinoma	864	903	896	788	3451
Lobular carcinoma	156	170	163	137	626
Mucinous carcinoma	205	222	196	169	792
Papillary carcinoma	145	142	135	138	560

Оригинальные изображения из набора данных имеют размер 700x460 пикселей. Предварительные испытания показали, что обучение нейронных сетей на входных данных такого размера проводить просто невозможно (просто недостаточно памяти). Поэтому для обучения использовались изображения с размером 227x227.

Для разделения набора данных на обучающую и тестирующие части, набор файлов случайно перемешивался, а потом делился в соотношении 80/20 по сохранению файловой структуры обоих выходных результирующих наборов.

Поскольку количество изображений ограничено, то данные автоматически вырезались из середины оригинального изображения (где вероятность идентификации заболевания наибольшая), и дополнительно с некоторым перекрытием центрального изображения (дополнительно еще 8 изображений). Все изображения зеркально отражались как горизонтально, так и вертикально. Все вырезанные файлы имели оригинальное название и дополнительно индекс, определяющий положение вырезанного изображения относительно оригинального. Структура файловой системы в результирующем наборе также сохранялась. Размер результирующего набора данных составлял примерно 14 гигабайт. Количество изображений в исходном наборе составляла 213 846.

Из таблицы 3 видно, что распределение количества изображений по отношению к количеству классов неравномерно. Поэтому перед обучением количество изображений для всех классов выравнивалось относительно класса с наименьшим количеством изображений избежание предвзятости.

Выбор гиперпараметров обучения моделей

Поскольку сгенерированный набор данных достаточно велик, использовать метод стохастического градиентного спуска просто невозможно. В работе использовался метод минипакетного стохастического градиентного спуска с размером пакета 16 (для того, чтобы можно было разместить модель в памяти GPU).

Проведенный предварительный анализ обучения сетей показал, что использовать одинаковое значение параметра скорости обучения также невозможно. Как известно, использование достаточно большого значения скорости обучения приводит к тому, что алгоритм градиентного спуска будет проходить мимо точки минимума и сходиться не будет [Микуллуччи, 2020].

Поэтому в работе использовался метод последовательного уменьшения скорости обучения. Диапазон значений скорости обучения колебался в пределах [0.001, 0.00001] с постепенным уменьшением при увеличении номера итерации. Таким образом удалось научить все модели. В таблице 4 указано количество эпох, которые использовались для обучения моделей.

Таблица 4. Количество эпох обучения различных типов сверточных сетей (CC)

модель	40X	100X	200X	400X	все изображения
Простая сверточная сеть	100	100	100	100	100
VGG16	50	50	100	100	100
VGG19	100	100	-	100	100
ResNet50v2	50	30	30	30	30
Inception	30	30	30	30	30
Xception	30	30	30	30	30

Как показано в таблице 3, простую сверточную нейронную модель, модели VGG16 и VGG19 удалось обучить при количестве эпох 100. Другие модели оказалось возможным обучить при количестве эпох 30.

Время, затраченное на обучение моделей VGG16, VGG19 при использовании всех изображений составляло примерно 12:00. Минимальное время, затраченное на обучение моделей при каком-то конкретном выборе масштаба увеличения изображения, составляло примерно 3:00. Нужно отметить, что примерное время полного обучения моделей составило более двух недель непрерывной работы компьютера.

Результаты бинарной классификации изображений

В таблице 5 приведена точность бинарной классификации (доброкачественная опухоль / злокачественная опухоль) тренированных моделей. В данном исследовании обучение на наборе данных при увеличении 200x проводилось для выяснения выбора гиперпараметров обучения. Лучшая модель Xception использовалась для обучения на всем наборе. Точность бинарной классификации этой модели составила 98,81% что является очень хорошим результатом обучения модели на несколько ограниченном наборе данных.

Таблица 5. Точность бинарной классификации изображений)

модель	200X	все изображения
Простая сверточная сеть	83,6%	83,0%
VGG16	90,9%	90,1 %
VGG19	97,6%	97,2%
ResNet50v2	84,4%	84,3 %
Inception	91,7%	91,3 %
Xception	99,75%	98,81%

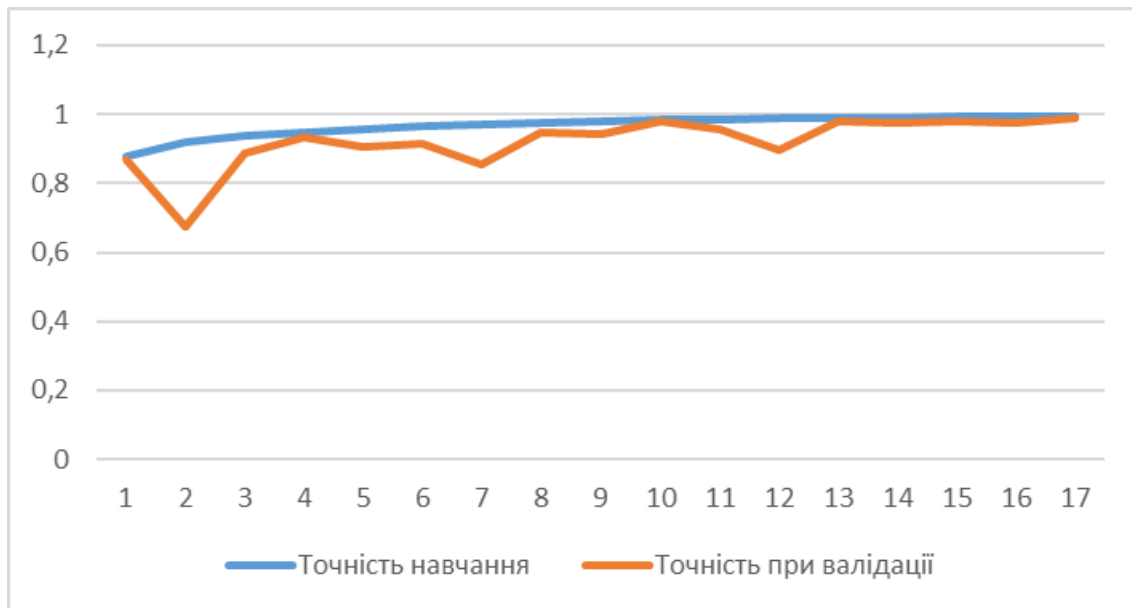


Рис. 2. Точность обучения и точность валидации модели Xception на всем наборе данных.

Как можно видеть из рис.2, при обучении модели было трудно найти минимальное значение времени градиентного спуска. Использование последовательного уменьшения параметра скорости обучения исправило ситуацию и для полного обучения модели нужно было всего 13 эпох.

Результаты многоклассовой классификации изображений

Представляет большой интерес возможность многоклассовой классификации выбранных моделей: adenosis , fibroadenoma , phyllodes tumor , tubular adenoma , ductal carcinoma,

lobular carcinoma, mucinous carcinoma, papillary carcinoma.

На рис. 3 - 5 приведены результаты скорости обучения моделей для многоклассовой классификации

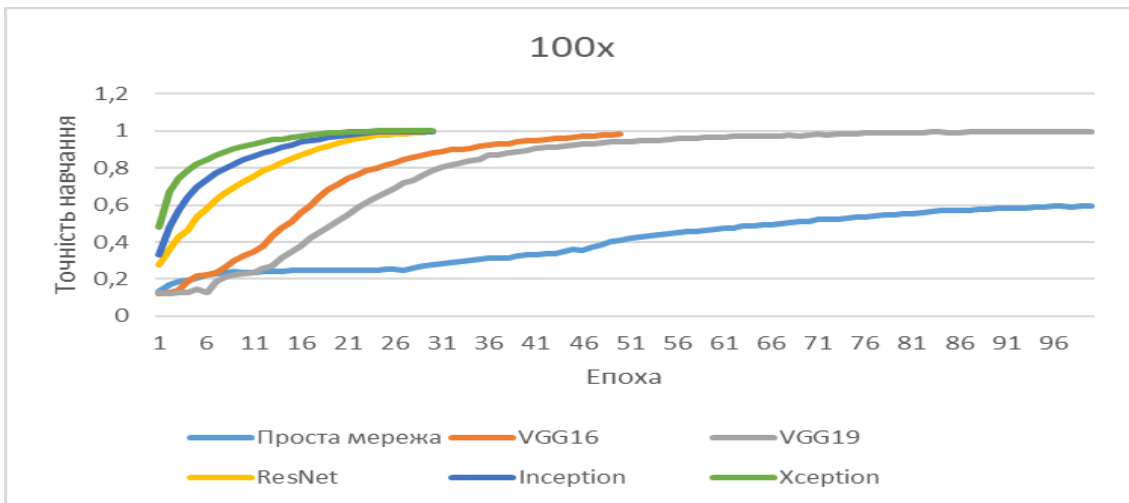


Рис. 3. Скорость обучения моделей при кратности изображений 100x.




Рис. 4. Скорость обучения моделей при кратности изображений 200x.

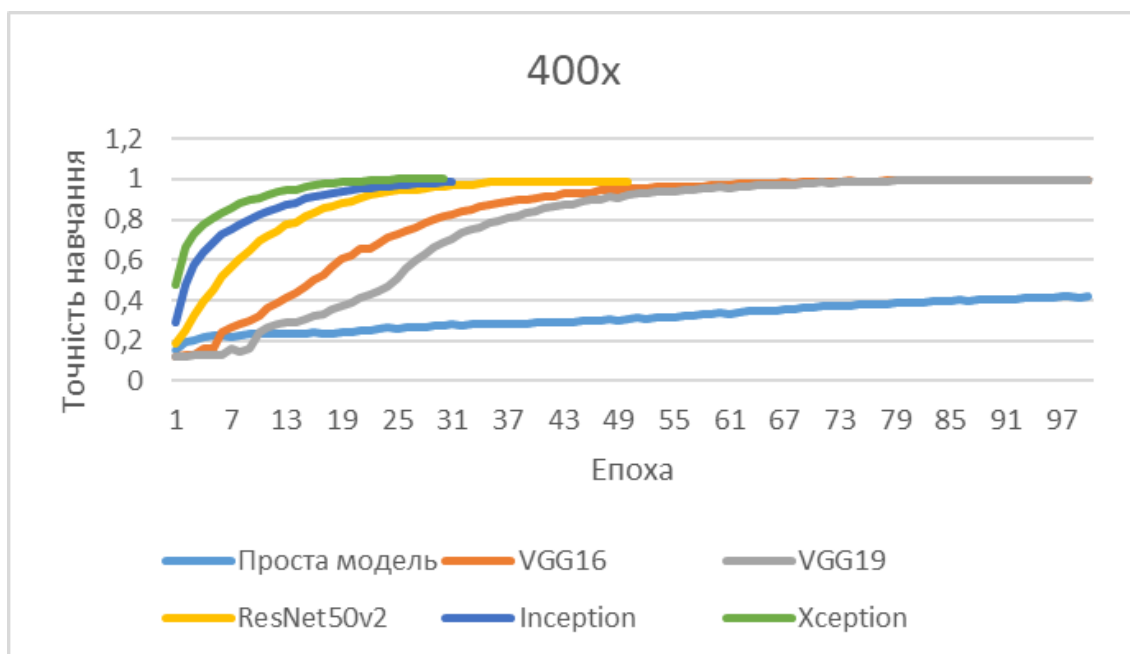


Рис. 5. Скорость обучения моделей при кратности изображений 400x.

Из приведенных рисунков можно видеть, что скорость моделей не одинакова, а зависит от архитектуры модели. Медленнее всего учится самая простая модель, быстрее всех является модель Xception. Обучение моделей на всем наборе данных приводит к повышению скорости обучения, так как, наверное, повышает способность моделей к обобщению.

Результаты точности классификации моделей на проверочном наборе приведены в таблице 6.

Таблица 6. Точность классификации по типу заболевания

модель	40X	100X	200X	400X	все изображения
Простая сверточная сеть	49,6%	54,7%	42,8%	39,8%	72,8%
VGG16	86,3%	90,8%	87,7%	85,7%	89,95%
VGG19	86,2 %	88,2%	-	88%	88,4%
ResNet50v2	84,4%	84,7%	82,8%	83,2%	86,1%
Inception	83,04%	85,6%	84,09%	75%	82,2%
Xception	90,6%	89 0 %	88,6%	89%	90,8%

Из таблицы можно видеть, что победителем в данном случае оказалась модель Xception .




Рис. 6. Обучение простой модели при использовании набора из всех возможных кратностей изображений.

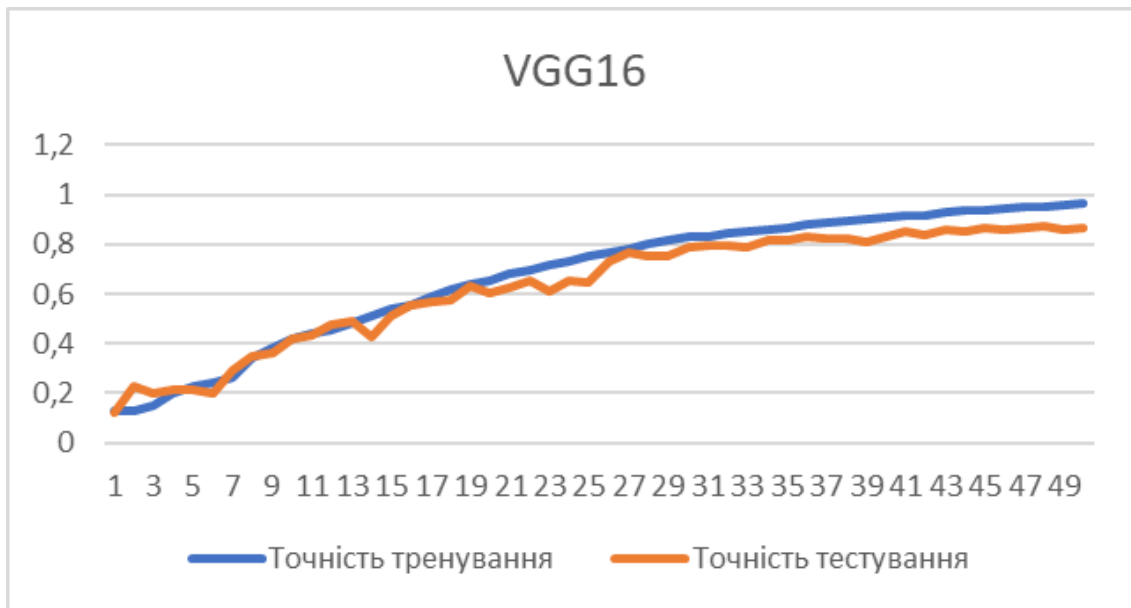


Рис. 7. Обучение модели VGG16 при использовании набора из всех возможных кратностей изображений.




Рис. 8. Обучение модели VGG19 при использовании набора из всех возможных кратностей изображений.




Рис. 9. Обучение модели InceptionV3 при использовании набора из всех возможных кратностей изображений




Рис. 10. Обучение модели Xception при использовании набора из всех возможных кратностей изображений

Были проведены сравнительные экспериментальные исследования рассмотренных в работе архитектур и моделей сверточных сетей с известными работами, которые использовали тот же датасет BreakHis [Singh], [Zaychenko, 2018].

Сравнительные результаты приведены в табл.7 для задачи бинарной классификации опухолей молочной железы.

Таблица 7. Количество эпох обучения различных типов сверточных сетей (CC)

классификатор/коэффициент усиления	200X	Все изображения
Линейная SVM[Singh]	88%	88%
Полиномиальная SVM[Singh]	89%	85%
Random forest [Singh]	87.74%	80%
NEFCClass [Zaychenko, 2018]	90.5%	90%
VGG 19	97,6%	97,2%
Inception	91,7%	91,3 %
Xception	99,75%	98,81%

Как следует из приведенных результатов, сверточные сети VGG 19 и Xception, исследованные в статье, оказываются наиболее эффективными для решения задачи классификации рака молочной железы.

Выводы

1. В статье проведено исследование эффективности сверточных сетей различных архитектур в задаче обработки медицинских изображений и классификации опухолей молочной железы. В исследованиях использовался стандартный датасет BreaKHis. Поскольку данный набор данных имеет ограниченный размер, а обучение моделей на оригинальных изображениях проводить невозможно из-за большого объема информации исходных изображений, то использовалась предварительная подготовка данных и генерировался набор данных изображений размером 227x227.
2. Для повышения сходимости моделей использовался метод уменьшения параметра скорости обучения при увеличении номера итерации.
3. В работе решалась проблема бинарной классификации изображений. Достигнута точность бинарной классификации изображений 98,81% в тестовом наборе с использованием модели Xception .
4. Дополнительно в работе решалась проблема многоклассовой классификации изображений. Установлено, что модели VGG 16 и VGG 19 для обучения требуют гораздо большего количества итераций, чем модели ResNet 50 V 2, Inception и Xception.
5. Проведены экспериментальные сравнения предложенных в статье моделей и методов классификации рака молочной железы с известными работами. Наилучшей оказалась модель Xception с использованием оригинального классификатора, точность многоклассовой классификации которой составила 90,8%.
6. В результате проведенных исследований установлено, что сверточную сеть модели Xception целесообразно использовать для экспресс-диагностики медицинских изображений для классификации раковых заболеваний молочной железы.

References

- [Siegel, 2019] R.L. Siegel, K.D. Miller, and A. Jemal, “Cancer statistics, 2019”. CA: A Cancer Journal for Clinicians, vol. 69(1), pp. 7–34, 2019.
- [Grunfeld, 2004] E. Grunfeld et al., “Family caregiver burden: results of a longitudinal study of breast cancer patients and their principal caregivers”, CMAJ, vol. 170(12), pp. 1795–1801, 2004.
- [Kale and Carroll,2016] H.P. Kale and N.V. Carroll, “Self-reported financial burden of cancer care and its effect on physical and mental health-related quality of life among US cancer survivors”, Cancer, vol. 122(8), pp. 283–289, 2016.
- [<https://costsofcare.org/the-costs-of-breast-cancer-in-the-u-s/>] “The costs of breast cancer in the U.S.”, care Co, 2019. Available: <https://costsofcare.org/the-costs-of-breast-cancer-in-the-u-s/>
- [Zhang 2013] Y. Zhang, B. Zhang, F. Coenen, and W. Lu, "Breast cancer diagnosis from biopsy images with highly reliable random subspace classifier ensembles ," Machine Vision and Applications, vol. 24 no. 7, pp. 1405- 1420,2013.
- [Zhang, 2014] Y. Zhang, B. Zhang, F. Coenen, J. Xiau , and W. Lu, "One-class kernel subspace ensemble for medical image classification," EURASIP Journal on Advances in Signal Processing, vol. 2014, no. 17 pp. 1-13,2014.
- [Doyle, 2008] S. Doyle, S. Agner, A. Madabhushi , M. Feldman, and J.Tomaszewski , "Automated grading of breast cancer histopathology using spectral clustering with textural and architectural image features," in Proceedings of the 5th IEEE International Symposium on Biomedical Imaging (ISBI): From Nano to Macro, vol. 61. IEEE, May 2008, pp.496-499.
- [Bengio, 2013] Y. Bengio, A. Courville, and P. Vincent, “Representation learning:A review and new perspectives,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 35, pp. 1798–1828,2013.
- [Singh ,] Aditi Singh, Hadi Mansourifar , Hasnain Bilgrami , Nikhil Makkar, Tanay Shah. Classifying Biological Images Using Pre-trained CNNs. <https://docs.google.com/document/d/1H7xVK7nwXcv11CYh7hl5F6pM0m218FQloAXQODP-Hsg/edit?usp=sharing>

- [Spanhol, 2016] F. Spanhol, LS Oliveira, C. Petitjean, and L. Heutte , "A dataset for breast cancer histopathological image classification," IEEE Transactions of Biomedical Engineering, 2016.
- [LeCun, 2015] Y. LeCun , Y. Bengio , and G. Hinton, "Deep learning," Nature, vol. 521, pp. 436-444, 2015.
- [Krizhevsky , 2012] A. Krizhevsky , I. Sutskever , and G. E. Hinton, " Imagenet classification with deep convolutional neural networks," in Advances in NeuralInformation Processing Systems 25 2012, pp.1097-1105.
- [Zaychenko, 2018] Yu.Zaychenko, G. Hamidov, I. Varga. Medical images of breast tumors diagnostics with application of hybrid CNN –FNN network. . Системні дослідження та інформаційні технології. 2018. №4.-с.37-47.
- [Микуллуччи, 2020] Микуллуччи У. Прикладное глубокое обучение. Подход к пониманию глубоких нейронных сетей на основе метода кейсов. [Текст]: Пер. с англ. – СПб.: БХВ-Петербург, 2020. – 368 с.
- [Zaccone, 2017] Zaccone Giancarlo. Deep Learning with TensorFlow [Текст]: / Giancarlo Zaccone, Rezaul Karim, Ahmed Menshawy. - Packt Publishing, 2017. - 316с.
- [Zgurovsky , 2016] M. Zgurovsky , Yu. Zaychenko. The Fundamentals of Computational Intelligence: System Approach. Springer International Publishing AG, Switzerland.- 2016-308р.
- [<https://www.cs.toronto.edu/~frossard/post/vgg16/>] VGG in TensorFlow [электронный ресурс]. – Режим доступа: <https://www.cs.toronto.edu/~frossard/post/vgg16/> .
- [<https://arxiv.org/abs/1512.03385>] Deep Residual Learning for Image Recognition [электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/1512.03385>.
- [<https://www.machinelearningmastery.ru/neural-network-architectures-156e5bad51ba>] Архитектура нейронной сети [электронный ресурс]. – Режим доступа: <https://www.machinelearningmastery.ru/neural-network-architectures-156e5bad51ba/> .
- [Chollet,2017] Chollet F. Xception: Deep Learning with Depthwise Separable Convolutions [электронный ресурс]. – Режим доступа :https://openaccess.thecvf.com/content_cvpr_2017/papers/Chollet_Xception_Deep_Learning_CVPR_2017_paper.pdf .

Acknowledgement

This paper is published with financial support by ITHEA ISS (www.ithea.org) and the ADUIS (www.aduis.com.ua)

Authors' Information



Yuri Zaychenko – Professor, doctor of technical sciences, Institute for applied system analysis, NTUU “KPI”, 03056, Ukraine, Kyiv, Peremogi pr. 37, Corpus 35; e-mail., zaychenkoyuri@ukr.net.

Major Fields of Scientific Research: Information systems, Fuzzy logic, Decision making theory, artificial intelligence



Galib Hamidov- PhD, doctor philosophy of technical sciences, “Bakielektrikshebeke” JSC, Head of the Information technologies department, AZ 1065, Azerbaijan, Baku, Kazimzade st. 20, e- mail: galib.hamidov@gmail.com

Major Fields of Scientific Research: Information technologies, Data Mining

Study of Convolutional Neural Networks in the Processing of Medical Images and Classification of Breast Tumors

Yu.P. Zaichenko, G. Gamidov

Abstract: *The problem of medical images analysis and classification of breast tumors is considered. For its solution the application of different convolutional neural networks CNN VGG16, VGG19, ResNet50 v 2, Inception u Xception is suggested. The experimental investigations of the suggested CNN on the standard data set BreakHis were carried out in problems of binary and multi-class classification. The comparison with known results was performed and efficiency of different CNN was estimated. The best class of CNN for this problem was determined with the highest accuracy.*

Key words: *breast cancer classification, medical diagnostics, CNN, accuracy*