

Правительство Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего профессионального образования
«Санкт-Петербургский государственный университет»
Кафедра информационно-аналитических систем

Алимпьева Анастасия Владимировна
Методы глубокого машинного обучения для
обнаружения аномалий в рентгеновских
СНИМКАХ

Бакалаврская работа

Научный руководитель:
к.ф.-м.н., старший преподаватель кафедры информатики СПбГУ
Салищев С. И.

Рецензент:
к.ф.-м.н., доцент кафедры параллельных алгоритмов СПбГУ
Иванцова О. Н.

Санкт-Петербург
2018

SAINT-PETERSBURG STATE UNIVERSITY

Chair of Analytical Information Systems

Alimpyeva Anastasia Vladimirovna

Deep Learning for abnormality detection in
Chest X-Ray images

Bachelor's Thesis

Scientific supervisor:

Senior Lecturer Salishev Sergei Igorevich

Reviewer:

associate professor Ivantsova Olga Nikolaevna

Saint-Petersburg

2018

Содержание

Введение	4
1. Постановка задачи	6
2. Обзор	7
2.1 Основные понятия	7
2.2 Предварительная обработка данных	12
2.2.1 Гистограммная эквализация снимков	12
2.2.2 “Вырезание” легких.....	13
2.3 Архитектуры сверточных нейронных сетей.....	15
2.3.1 GoogLeNet.....	15
2.3.2 Inception-V3	17
2.3.3 ResNet.....	19
3 Реализация	21
4 Результаты и их сравнение	22
5 Заключение	25
6 Список литературы	26

Введение

Медицинские рентгеновские снимки являются одним из первых и основных вариантов диагностики различных заболеваний. Рентгенограммы, благодаря наличию широкого спектра информации, анализ которого позволяет не только выявить на ранних стадиях и поставить точный диагноз заболевания, но и отслеживать динамику процесса лечения, получили широкое распространение в медицинской практике. В то же время, автоматизированное обнаружение аномалий на снимках, позволяющее снизить нагрузку на специалистов - рентгенологов, повысить эффективность обработки данных и как следствие, повысить точность диагноза остается приоритетным направлением развития информационных технологий.

По оценке специалистов, врач-рентгенолог за день может качественно обработать не более 200 рентгенограмм. В густонаселенных районах врач-рентгенолог вынужден изучать гораздо большее число снимков, что неизбежно влечет за собою снижение качества обработки информации, содержащейся в рентгенограмме. Практика показывает, что сложность в работу специалиста вносит не только все увеличивающееся количество снимков, но и их качество, зависящее от ряда параметров: содержание посторонней информации (наличие кардиостимуляторов, операционных швов, проводов и т.п.), оптические шумы (засветка, затемнение), анатомические особенности тела пациента.

Перспективным решением поставленной задачи автоматизированного обнаружения аномалий на рентгеновских снимках являются применение сверточных нейронных сетей, которые занимают лидирующие позиции, среди программных средств, применяемых для обработки и анализа изображений. Для решения задачи классификации фронтальных рентгеновских снимков по поиску туберкулеза Alvin Rajkomar, Sneha Lingam и др. использовали сверхточную нейронную сеть GoogLeNet, предварительно обученную на наборе данных ImageNet [1]. Это служит доказательством эффективного использования концепции глубокого

машинного обучения на рентгенограммах грудной клетки. Кроме того, сверточная нейросеть показала высокие результаты при поиске рака на рентгенограммах грудной клетки [2]. Классификация снимков на нормальные (здоровые) и с аномалиями существенно бы помогла работе специалистов на первичном этапе диагностики.

В данной работе произведен анализ архитектур сверточных нейронных сетей, описанных в статье авторов Darvin Yi, Archana Shenoyas и др. [3], в рамках задачи классификации рентгеновских снимков грудной клетки с добавлением метода обработки снимков, а именно - сегментации легких. Полученные результаты в данной работе говорят о том, что увеличение глубины сетей улучшает результаты их работы лишь на малое количество значений, что говорит о том, что уход в глубину не сильно существенен для решения данной задачи. Так, например GoogLeNet дает следующие значения F1-меры - 0.78, precision - 0.85. Более глубокие нейронные сети обладают следующими значениями F1-меры - 0.80, precision - 0.85 и 0.89. Несмотря на близкие значения данных метрик у всех архитектур, GoogLeNet также дает самые низкие показатели по метрикам recall и accuracy, что может говорить о том, что использование сетей с большим количеством слоев предпочтительнее для распознавания аномалий на рентгенограммах грудной клетки.

1. Постановка задачи

Целью данной работы является исследование сверточных нейронных сетей различных архитектур в ходе решения задачи поиска аномалий на рентгенограммах грудной клетки. Для достижения цели выполнены следующие задачи:

- Сделать обзор предметной области
- Выбрать и подготовить набор данных для обучения
- Провести предварительную обработку снимков
- Выбрать архитектуры сверточных нейронных сетей и реализовать их
- Проанализировать результаты реализации каждой нейронной сети и осуществить их сравнительный анализ

2. Обзор

2.1 Основные понятия

Для обучения сверточных нейросетей для классификации объектов необходимо подготовить два набора данных - обучающий (train dataset) и тестовый (validation dataset). Train dataset предполагается использовать для обучения нейросети, validation dataset - для проверки ее работы. Задача классификации формулируется следующим образом: имеется множество объектов, для некоторых из них известно, к каким классам они принадлежат; для других объектов их классовая принадлежность неопределенна, и требует их распределения.

Сверточные нейросети (Convolution Neural Networks, CNN) в общем виде представлены на рисунке 1. Входные данные у таких сетей, как правило, состоят из изображений. Слои CNN состоят из нейронов, расположенных в 3-х измерениях: ширине, высоте и глубине. Основные слои данной нейросети представлены сверточным слоем (convolution), субдискретизирующим (pooling) и полносвязным [4].

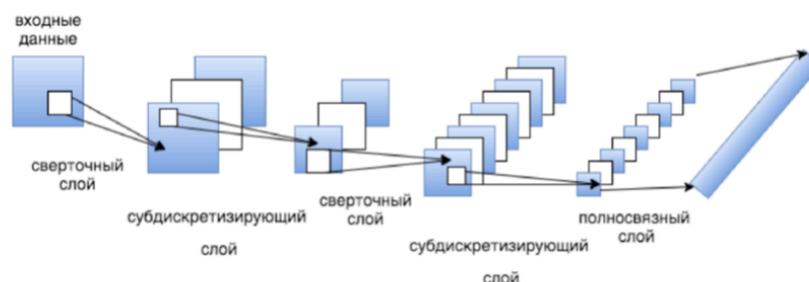


рисунок 1. Общий вид CNN

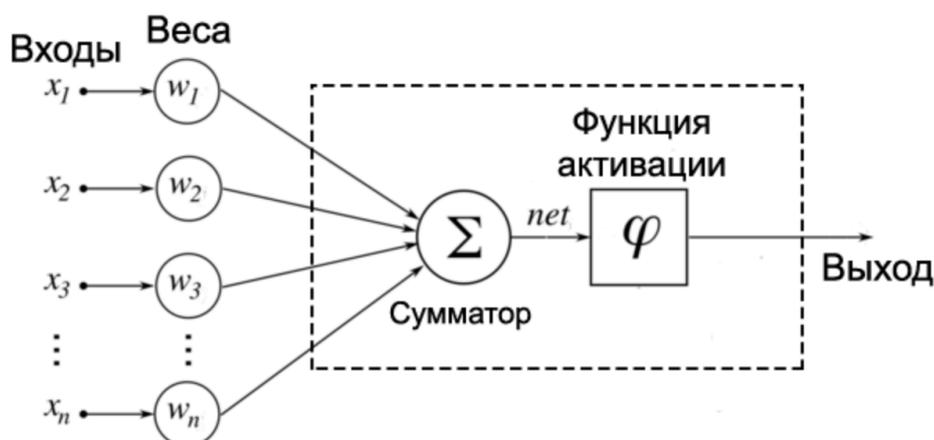
Сверточный слой накладывая ядро свертки, поэлементно умножает значения фильтра и изображения всеми возможными способами, и записывает сумму произведений элементов исходного изображения и ядра. Как правило, применяется не одно ядро свертки, а сразу несколько. Результатом работы данного слоя становятся карты признаков. Pooling слой

выполняет операцию по понижению дискретизации пространственных размеров изображения. Наконец, полносвязный слой берёт входные данные и выводит N-пространственный вектор, где N — число классов, из которых нейронная сеть выбирает нужный. Способ, с помощью которого работает полносвязный слой — это обращение к выходу предыдущего слоя (в данном случае, это карты свойств) и определение свойств, которые больше связаны с определенным классом.

Стоит отметить, что на вход такой нейросети обычно подаются тензоры, т. е. трехмерный вектор, который содержит в себе информацию о ширине и высоте изображения, а также о количестве его каналов. Например, если у нас изображение формата RGB, то количество каналов равно трем.

Также данные нейросети чаще всего для обучения используют метод обратного распространения ошибки. Обучение данным алгоритмом представляет собой два прохода: прямой и обратный. Прямой проход представляет собой прием входного вектора на первом слое сети, а затем его распространение от слоя к слою, при этом синоптические веса не изменяются. В результате получается вектор, который и является выходом сети. При обратном проходе происходит настраивание весов в направлении противоположном предыдущему. То есть синоптические веса настраиваются с целью минимизации ошибки, путем вычисления разности между выходом сети и требуемым выходом. В простейшем случае корректировка происходит согласно следующей формуле: $E(w_{i,j}) = 1/2 \sum_{k \in OUT} (t_k - o_k)^2$, где E - функция ошибки, $w_{i,j}$ - синоптический вес между нейронами i и j , t_k - правильные ответы, o_k - выход k -того нейрона, OUT - множество выходов сети. Затем происходит настройка весов, путем градиентного спуска, то есть движения в пространстве весов в сторону противоположную градиенту до минимального значения ошибки. Настройка весов производится согласно следующей формуле: $\Delta w_{i,j} = -\eta \frac{dE}{dw_{i,j}}$, где η - параметр, характеризующий скорость движения и $0 < \eta < 1$.

Для обучения нейронных сетей также необходимо задать функцию активации. На рисунке 2 показана модель искусственного нейрона.



рисунк 2. Модель искусственного нейрона

Нейрон имеет входы x_1, x_2 и т.д., которые имеют веса w_1, w_2 и т.д. Первоначально веса задаются произвольными небольшими числами, а затем настраиваются методом обратного распространения ошибки. Сумматор - функция, которая складывает веса входного сигнала x . Функция активации вычисляет выходной сигнал нейрона. Чаще всего в сверточных нейронных сетях используется слой с полулинейной функцией активации (Rectified Linear Unit, relu) $f = \max(x, 0)$, где x - вход нейрона. Производная данной функции равна либо 0, либо 1. Поэтому данная функция эффективно борется как с разрастанием градиента при обратном проходе, так и с затуханием. Данное свойство приводит к прореживанию весов, что хорошо сказывается на работе глубоких нейронных сетей.

Для определения качества работы нейронной сети и сравнения их результатов рассмотрены следующие метрики: функция потерь (Loss), точность (Precision), полнота (Recall) и F1-мера [5]. На выходе нейронной сети в задачи классификации получаются вероятности, которые в сумме должны дать единицу. Функция потерь (Loss) характеризует суммирование ошибок, сделанных для каждого примера в какой-либо выборке. В качестве функции потерь в сверточных нейронных сетях чаще всего используется

перекрестная энтропия, определяемая следующей формулой на каждом шаге обучения: $L = - \sum_{i=1}^n t_i \log y_i$, где t_i - требуемые выходы для текущего

обучающего примера, y_i - реальные выходы нейронной сети. Общая ошибка будет вычисляться согласно следующей формуле:

$$L = - \frac{1}{Size} \sum_{\alpha \in DataSet} \sum_{i=1}^n t_i^{\alpha} \log y_i^{\alpha},$$

где $Size$ - размер обучающей или

валидационной выборки, $DataSet$ - сама эта выборка [6]. При работе нейронной сети возможны решения представленные в матрице ошибок (confusion matrix) на рисунке 3.

		Ожидаемое значение	
		Положительное значение	Отрицательное значение
Решение системы	Положительный ответ	истинно-положительные (True Positive TP)	ложно-положительные (False Positive FP)
	Отрицательный ответ	ложно-отрицательные (False Negative FN)	истинно-отрицательные (True Negative TN)

рисунок 3. Confusion matrix

Мера точности характеризует, сколько полученных от алгоритма положительных ответов являются правильными, однако она не дает информации о том, все ли правильные ответы вернул алгоритм. Поэтому еще говорят о мере полноты, которая характеризует способность алгоритма давать как можно больше положительных ответов из ожидаемых. Данные меры

считаются по следующим формулам: $Precision = \frac{TP}{TP + FP}$,

$$Recall = \frac{TP}{TP + FN}.$$

Ясно, что чем выше точность и полнота, тем лучше работает система. Но, как правило, максимальная точность и полнота не достижимы

одновременно и поэтому используют метрику F1-меры, которая объединяет в себе информацию о точности и полноте алгоритма. F1-мера представляет собой гармоническое среднее между точностью и полнотой, и вычисляется

согласно следующей формуле: $F1 = 2 \frac{Precision \times Recall}{Precision + Recall}$.

2.2 Предварительная обработка данных

2.2.1 Гистограммная эквализация снимков

Для увеличения качества изображений был использован метод гистограммной эквализации изображений. Выбор данного метода обусловлен наличием в наборе данных одноканальных изображений. Гистограммой одноканального изображения называют дискретную функцию, которая принимает значение, равное яркости пикселя. Гистограммная эквализация выполняет преобразование данной функции так, чтобы она была близка к равномерному распределению. В результате данной операции ожидается увеличение контрастности изображений (рисунок 4).

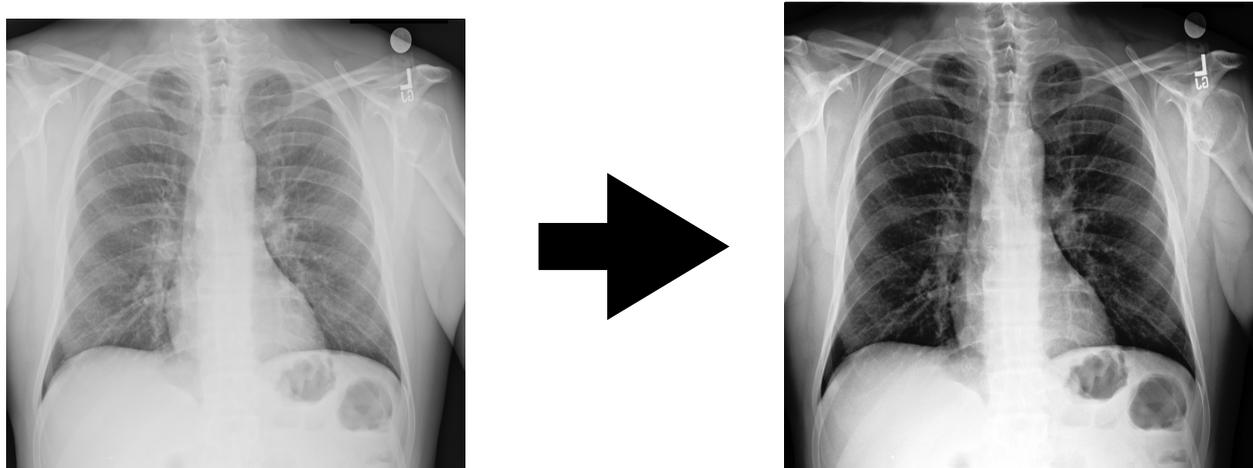


Рисунок 4. Результат применения метода гистограммной эквализации изображения

2.2.2 “Вырезание” легких

Несмотря на то, что для сравнения методов глубокого машинного обучения задача “вырезания” легких не первостепенна, в данной работе было сделано сегментирование рентгенограмм грудной клетки для снижения вычислительных ресурсов. Было взято около тридцати снимков и обнаружено, что полезной информации для обучения на снимке около 30% (рисунок 5).

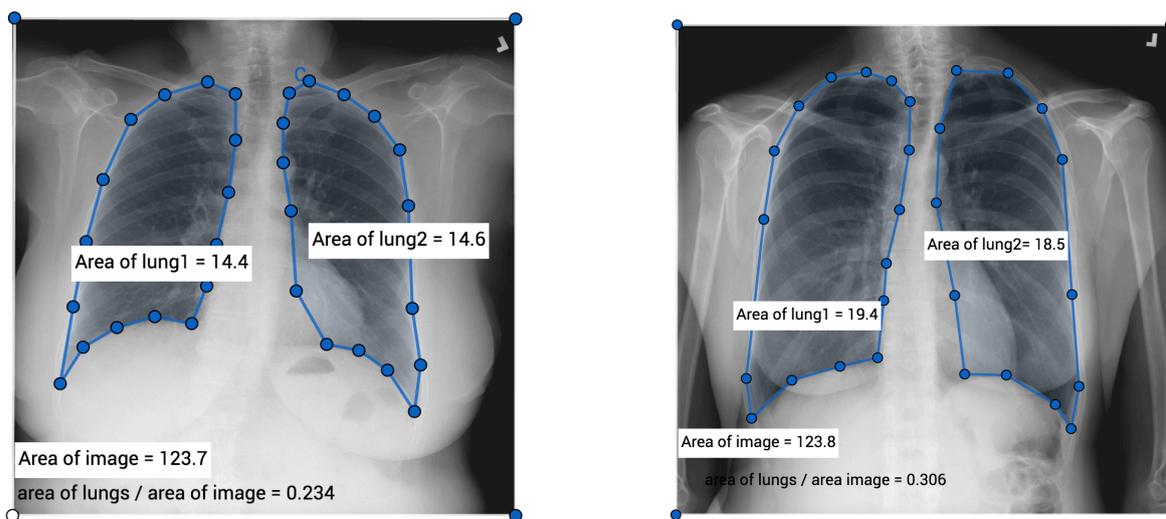


Рисунок 5. Соотношение площадей полезной информации для обучения и всего изображения

Это означает, что больше половины информации на снимках является лишней для решения данной задачи. Для данной задачи была использована сверточная нейронная сеть U-Net [7]. Данная нейронная сеть хорошо себя зарекомендовала в рамках решения задачи сегментации биомедицинских изображений. Архитектура данной сети представлена на рисунке 6. В данной архитектуре реализованы последовательно слои свертки, а затем субдискритизации. Данные слои сначала уменьшают разрешение изображения, а затем увеличивают его, объединяя с данными изображения, которое обработано другими слоями свертки.

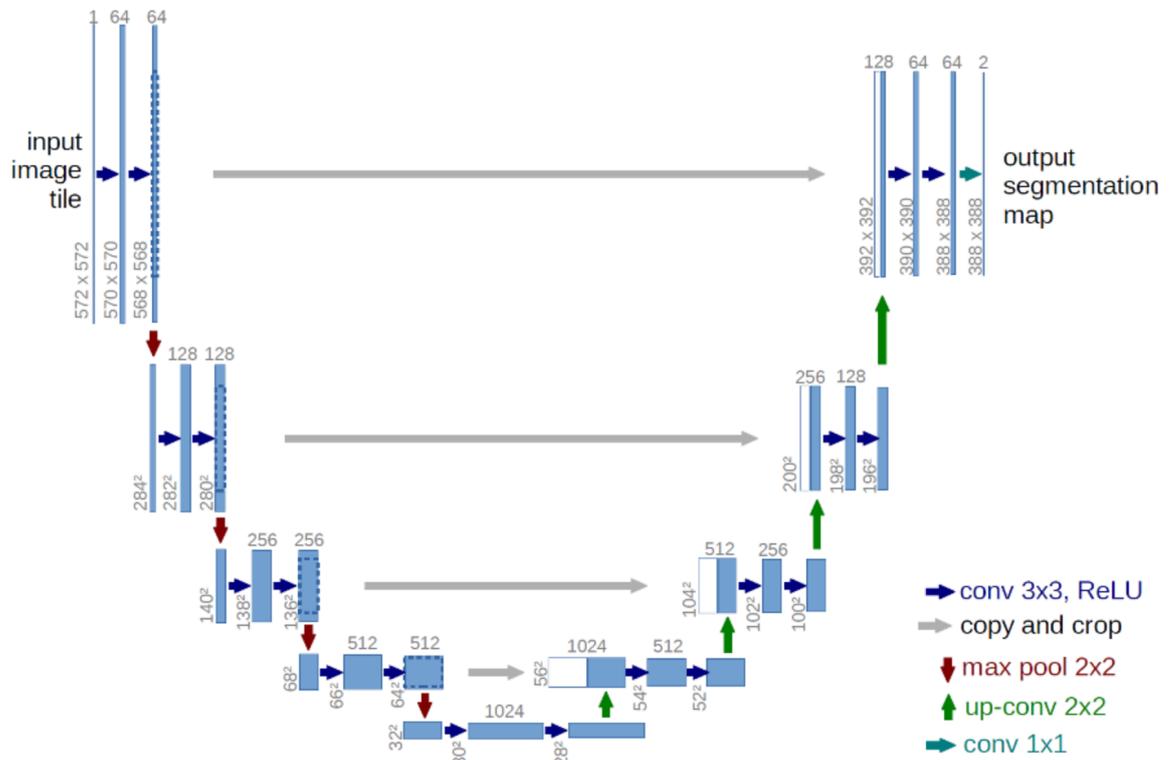


Рисунок 6. Архитектура U-Net

Выбранный в данной работе набор данных был сегментирован с использованием данной нейронной сети с подготовленными вручную “масками” на более маленьком наборе данных (Рисунок 7).

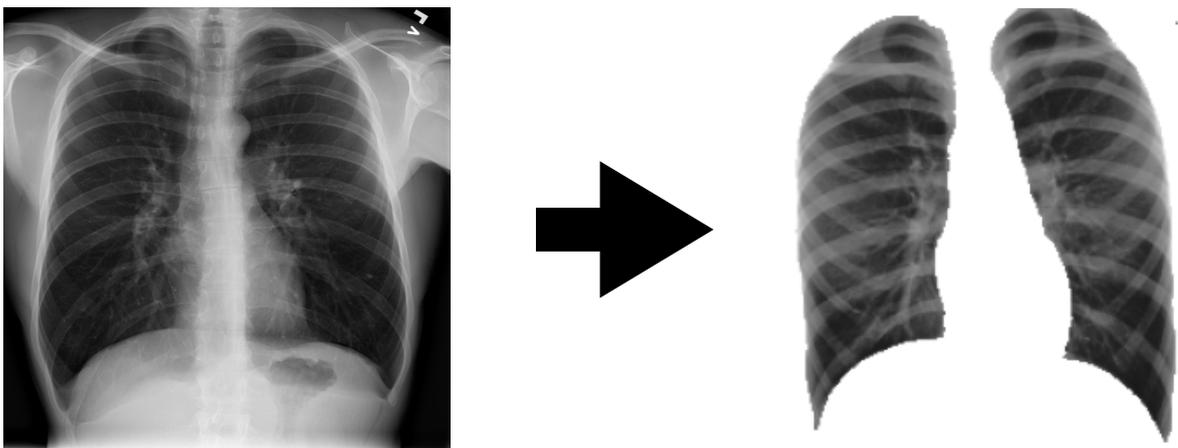


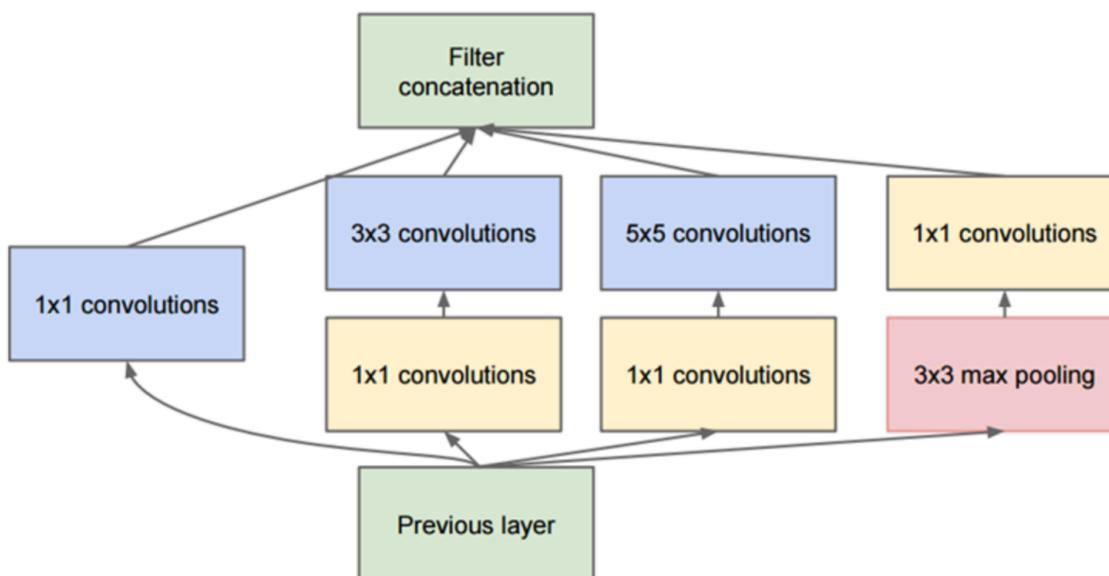
Рисунок 7. Пример результата работы U-Net для задачи сегментирования легких

2.3 Архитектуры сверточных нейронных сетей

В данном разделе рассмотрены особенности архитектур нейронных сетей, которые были использованы в данной работе.

2.3.1 GoogLeNet

GoogLeNet представляет собой сверточную нейронную сеть, которая не только показывает высокую точность, но и обладает сравнительно малым количеством вычислений [8]. Данная нейросеть выбрана для задачи определения аномалий на рентгенограммах грудной клетки, так как она не только является победителем ImageNet Recognition Challenge, но также данная сеть хорошо себя показала в рамках задачи распознавания рака молочной железы на рентгенограммах грудной клетки, что показывает ее эффективность при работе именно с медицинских изображений [9]. В данной архитектуре используются так называемые inception блоки. Пример такого блока показан на рисунке 8.



рисунк 8. Inception блок в нейронной сети GoogLeNet

Важно отметить, что такая сеть увеличивается не только в глубину, но и в ширину, путем параллельного использования сверток разного масштаба. В каждом блоке есть есть слои свертки с ядром разного размера, чтобы

распознавать признаки различного масштаба. Также в данной модели активно используются свертки 1×1 , чтобы уменьшать размерность тензоров, которые будут подаваться на вход следующему слою. Для того чтобы не потерять информацию, полученную в предыдущем слое также применяется субдискритизирующий слой. После него также применяется сверточный слой с ядром свертки 1×1 , в данном случае для того, чтобы выравнять размерность тензоров на выходе после каждого параллельного слоя. Затем происходит конкатенация карт признаков, полученных на каждом параллельном слое. В полной сети используется последовательно девять таких блоков.

2.3.2 Inception-V3

Данная архитектура использует ту же концепцию, что и GoogLeNet, пытаясь увеличивать глубину и сложность модели без чрезмерных вычислительных затрат [10]. Если заметить, то в предыдущей модели был слой свертки с размером матрицы 5×5 . Этот слой можно заменить двумя слоями свертки с матрицами 3×3 . Так потеряется небольшое количество информации, а количество параметров снизится. Затем, слой свертки 3×3 заменяется на свертки $3 \times 1 + 1 \times 3$. При таком подходе количество вычислений еще больше снизится. Далее можно сначала сделать субдискритизирующий слой, затем слой сверток или наоборот. В первом случае можно потерять довольно много информации, во втором случае затрачивается слишком много вычислительных затрат. Поэтому в данной модели предлагается гибридный подход. А именно мы увеличиваем количество каналов в два раза, и делаем и свертку, и субдискритизацию, пример на рисунке 9.

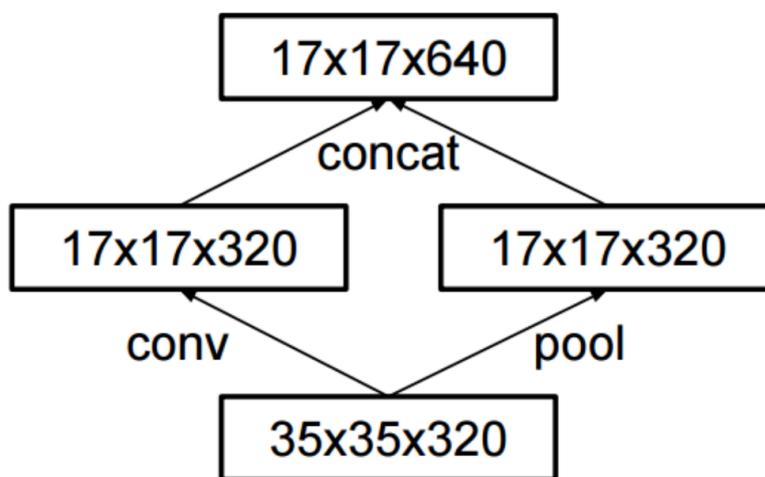


рисунок 9. Применение гибридного подхода

Предполагается, что со временем нейросеть научится определять для каких признаков необходимы будут изображения в полном разрешении, а для каких будет достаточно и уменьшенных. Кроме того, здесь применены свертки с шагом два и один (Stride 1, stride 2). Пример нового inception блока

можно увидеть на рисунке 10. Всего в данной сети находится 11 таких блоков.

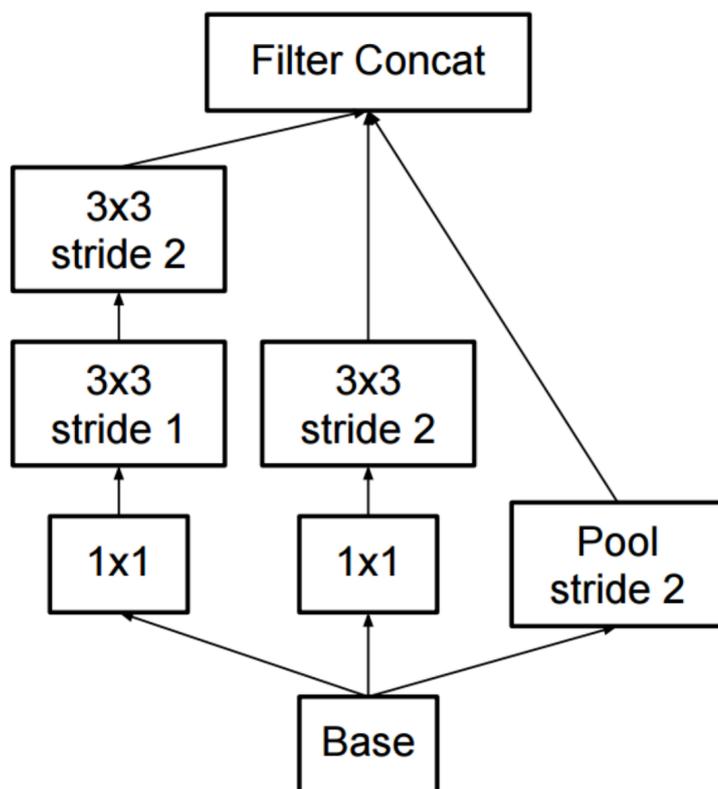


рисунок 10. Inception блок в нейронной сети Inception-V3

2.3.3 ResNet

Данная нейросеть является намного глубже по сравнению с предыдущими архитектурами [11]. Большинство нейросетей используют в качестве метода обучения используют метод обратного распространения ошибки. То есть при проходе обучающего примера и получения выхода, с целью уменьшения функции ошибки начинается обратный проход сети методом градиентного спуска. При увеличении глубины нейросети, одна из самых частых проблем - это затухание градиента при обратном проходе, и как следствие, ухудшение работы нейронной сети. В частности затухание градиента и потеря информации чаще всего случается из-за использования популярного слоя relu с функцией активации: $f = \max(x, 0)$. Во многих случаях при отсеивании ненужных признаков, как раз и получается значение 0, что и способствует затуханию градиента. В основе архитектуры данной сети лежат блоки, изображенные на рисунке 11.

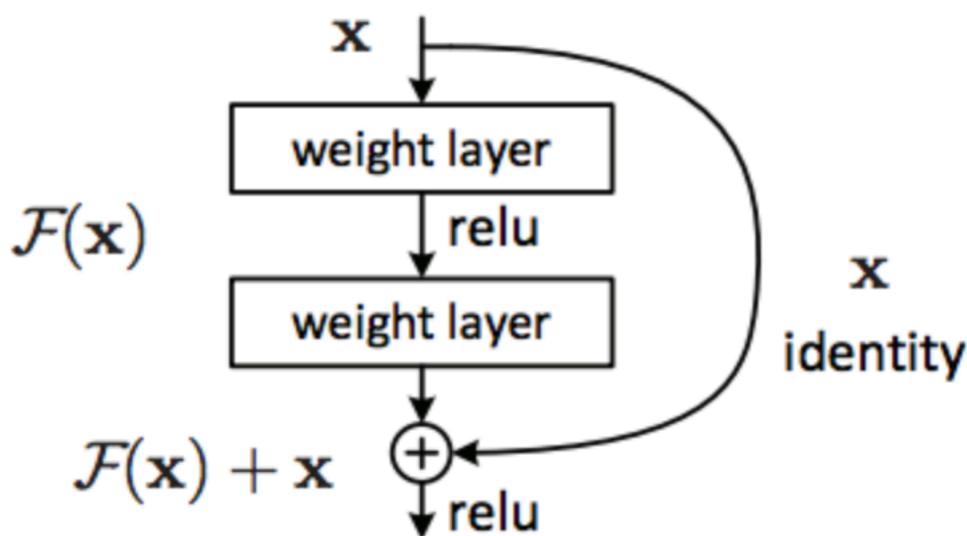


Рисунок 11. Блок с shortcut соединением в ResNet

Работа данного блока объясняется следующим образом: пусть целевая функция будет в виде $H(x) = F(x) + x$. При достигнутом пределе качества на предыдущем слое, для того чтобы не происходило затухание градиента, хотелось бы, чтобы функция $F(x)$ возвращала тождественное преобразование, однако этого не происходит, так как используется слой relu, и часто она

возвращает 0. В данной сети предлагают использовать, так называемые, shortcut соединения, то есть явно добавляется тождественное отображение. В итоге при обратном проходе получаем: $\frac{dF(x)}{dx} + \frac{dx}{dx}$, то есть $\frac{dF(x)}{dx} + 1$. Таким образом затухания градиента не произойдет, так как всегда будет выполнен обратный проход. Данная нейронная сеть состоит из последовательных блоков, вида показанного на рисунке 12 и содержит в себе 152 слоя.

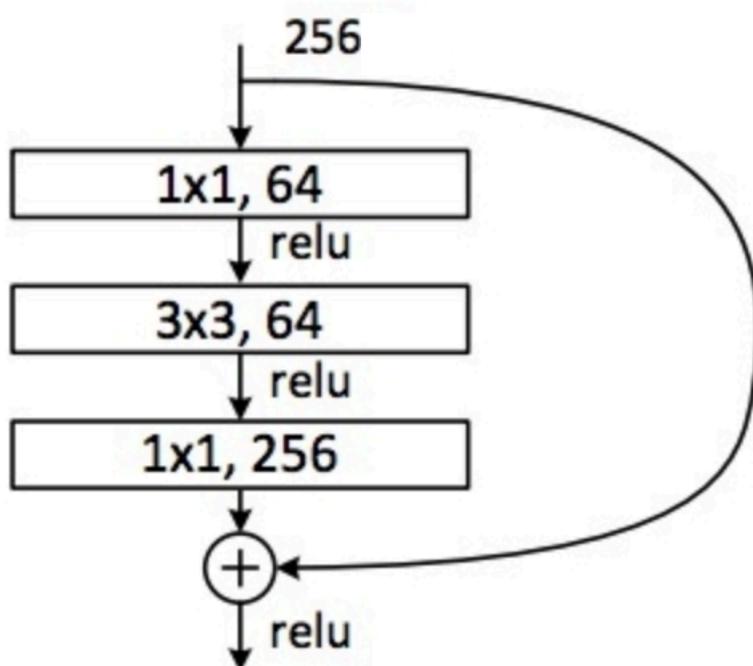


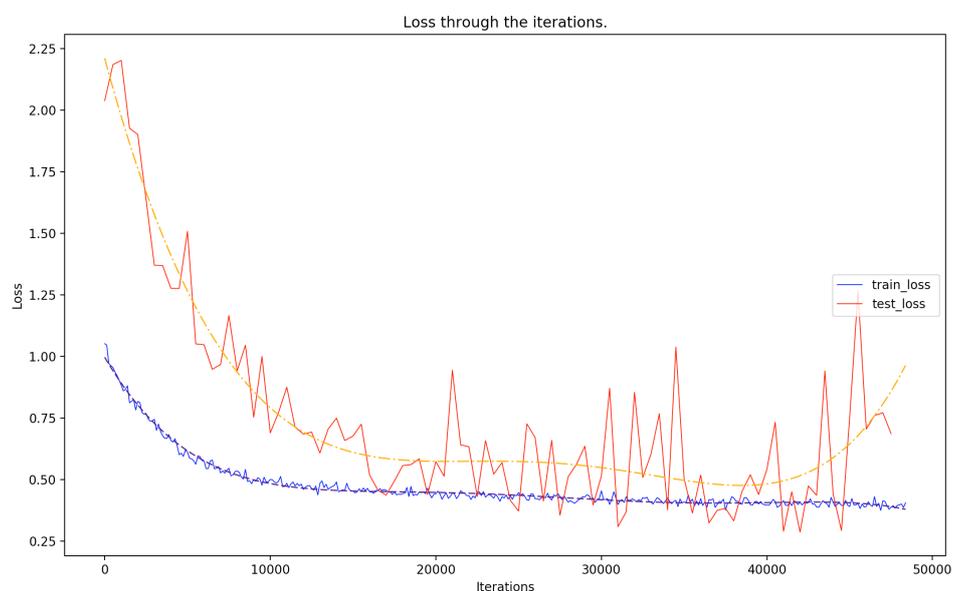
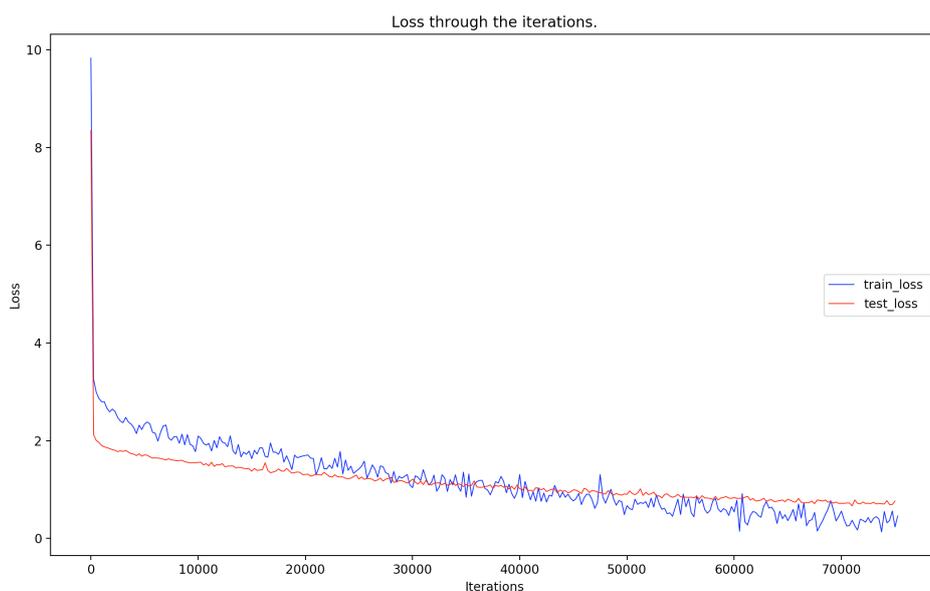
Рисунок 12. Блок с shortcut соединением в ResNet -152

3 Реализация

Для обучения нейронных сетей, представленных выше необходимо выбрать набор данных, на котором будет происходить обучение. В качестве такого набора был выбран набор NIH Chest X-rays Dataset клинического центра здоровья США, находящийся в свободном доступе [12]. Данный набор содержит около 112000 снимков, разделенных на здоровые и с патологиями. Изображения в данном наборе одноканальные, имеют размер 1024×1024 , в формате PNG. Кроме того, так как некоторые снимки сделаны с посторонними предметами, обладают плохим качеством и т.п., данный набор был просмотрен вручную, а такие снимки были удалены. В результате, осталось 27320 “здоровых” снимков и 13863 снимка - с аномалиями. Далее данные снимки были сжаты до размера 224×224 пикселя. Несмотря на значительное изменение размеров, данный датасет по прежнему обладает большим количеством снимков и пригоден для обучения. К изображениям были применены операции гистограммной эквализации и сегментации легких, описанные выше в 2.2.1 и 2.2.2. Затем данный набор был разделен в соотношении 90 : 10 на тренировочный набор данных и валидационный. В результате, валидационный набор содержит 4100 снимков, из которых 2700 здоровых снимков и 1400 снимков с аномалиями. Затем были обучены сверточные нейронные сети, описанные выше в 2.3.1, 2.3.2 и 2.3.3. Для этого используется язык программирования python 2.7 и библиотека для машинного обучения Caffe [13]. Во время обучения применялся метод стохастического градиентного спуска с learning rate 0.001 и Batch Size = 256. Для оценки функции потерь использовалась функция перекрестной энтропии.

4 Результаты и их сравнение

Первоначально была рассмотрена архитектура GoogLeNet, так как она показала хорошие показатели на ImageNet Recognition Challenge, а также на поиске аномалий молочной железы. Далее была рассмотрена схожая, но более глубокая архитектура Inception-V3, и затем была рассмотрена нейронная сеть ResNet, которая является представителем “остаточных” сетей. Как показано на рисунке 13, увеличение глубины архитектуры не позволяет существенно повысить производительность модели. Во всех случаях функция потерь принимает значение около 0.4. Дальнейшее уменьшение данной функции на тренировочном датасете, сопровождается увеличением разницы между значениями данной функции на тренировочном и валидационном датасете, что говорит о переобучении сети.



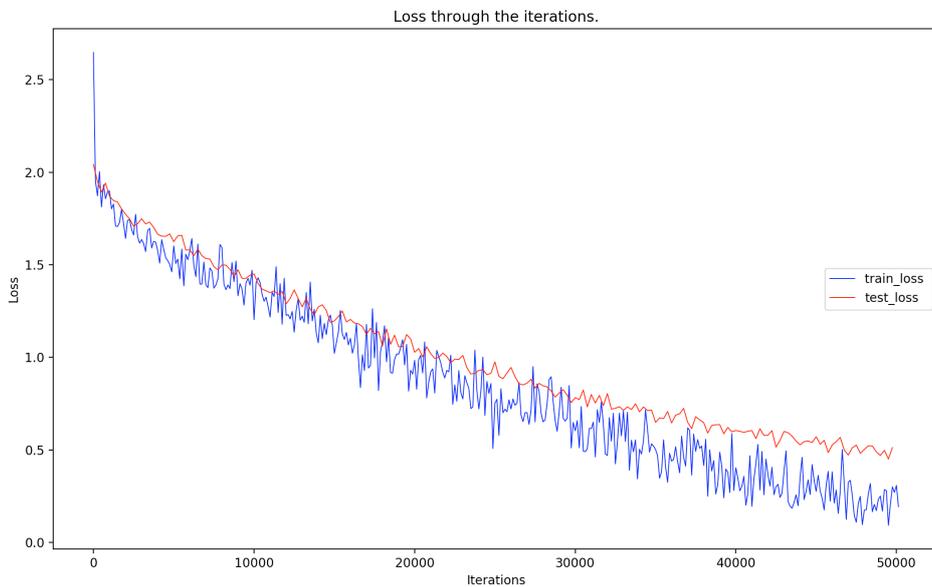


Рисунок 13. Зависимость функции потерь от количества итераций GoogLeNet, Inception-V3, ResNet.

На рисунке 14 можно увидеть сравнительную характеристику для каждой сети.

	GoogLeNet	Inception-V3	ResNet
f1	0.78	0.80	0.80
precision	0.85	0.89	0.85
recall	0.72	0.74	0.78
accuracy	74 %	76 %	77 %

Рисунок 14. Сравнительная таблица различных метрик для нейронных сетей GoogLeNet, Inception-V3, ResNet

Как видно, все архитектуры справились с задачей примерно на одном уровне. Однако по всем метрикам архитектура GoogLeNet показала себя чуть хуже остальных. Рассмотрим результаты архитектур Inception-V3 и ResNet. Несмотря на то, что их показатели качества работы - метрика f1 принимает одно и тоже значение, а также на то, что значение ассигасу выше, чем у

ResNet, именно для задачи распознавания аномалий на рентгенограммах грудной клетки архитектура Inception-V3 показывает лучшие результаты. Если взглянуть на confusion matrix этих сетей, то можно увидеть следующее: Inception-V3 классифицирует снимки с аномалиями как нормальные существенно меньше, чем ResNet (рисунок 15).

		Ожидаемое значение	
		Normal	Abnormal
Решение системы	Normal	1991	257
	Abnormal	709	1143

		Ожидаемое значение	
		Normal	Abnormal
Решение системы	Normal	2097	361
	Abnormal	603	1039

рисунок 15. Confusion matrix для валидационной выборки

У Inception-V3 - 257 снимков из 1400, у ResNet - 361 снимок. Это и отражено метрикой - precision. У Inception-V3 она выше. Следовательно, несмотря на то, что ResNet показала лучшие результаты на соревновании ImageNet, для классификации медицинских изображений лучше применять семейство сетей Inception, так как для медицинской тематики одной из главных задач является минимизация количества снимков с аномалиями, которые будут отмечены системой как норма.

5 Заключение

В рамках данной выпускной квалификационной работы достигнуты следующие результаты:

- Сделан обзор предметной области.
- Подготовлен набор данных для обучения.
- Произведена предварительная обработка рентгеновских снимков.
- Построены и обучены нейронные сети, выбранных архитектур.
- Представлен сравнительный анализ результатов работы нейронных сетей различных архитектур.

По результатам данной работы сделаны следующие выводы:

1. Архитектура нейронной сети GoogLeNet, хоть и показывает неплохие результаты по различным метрикам, немного уступает в качестве двум более глубоким архитектурам: Inception-V3 и ResNet.
2. Архитектуры нейронных сетей Inception-V3 и ResNet показывают очень близкие результаты. Их f1-мера совпадает на тестовой выборке. ResNet обладает более высоким значением метрики recall = 0.78. Но для практического применения значения recall должно быть около 0.99 и выше. Поэтому более предпочтительной архитектурой нейронной сети для решения задачи распознавания аномалий на рентгенограммах грудной клетки является нейронная сеть Inception-V3 с самым высоким показателем precision = 0.89. Увеличение значения в данной метрике выбрано, так как оно минимизирует количество снимков с аномалиями, распознанных системой как здоровые и позволяет сократить нагрузку на специалиста - рентгенолога.

6 Список литературы

- [1] High-Throughput Classification of Radiographs Using Deep Convolutional Neural Networks / Alvin Rajkomar, Sneha Lingam, Andrew G. Taylor, Michael Blum, and John Mongan // Journal of Digital Imaging. — Feb 2017 — P. 30 - 95.
- [2] Nodule Classification Using Deep Feature Fusion in Chest Radiography / Changmiao Wang, Ahmed Elazab, Jianhuang Wu, and Qingmao Hu. Lung. // Computerized Medical Imaging and Graphics: The Official Journal of the Computerized Medical Imaging Society — 2017 — P. 10 - 57.
- [3] Deep Learning for abnormality detection in Chest X-Ray images / Darvin Yi, Christine Tataru, Archana Shenoyas, Anthony Ma — 2017. — Access mode: <http://cs231n.stanford.edu/reports/2017/pdfs/527.pdf>
- [4] Wikipedia. Convolutional neural network. — 2018. — Access mode: https://en.wikipedia.org/wiki/Convolutional_neural_network
- [5] Wikipedia. Precision and recall. — 2018. — Access mode: https://en.wikipedia.org/wiki/Precision_and_recall
- [6] Wikipedia. Cross entropy. — 2018. — Access mode: https://en.wikipedia.org/wiki/Cross_entropy
- [7] U-Net: Convolutional Networks for Biomedical Image Segmentation / Ronneberger O., Fischer P., Brox T // Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS. — 2015. — Vol. 9351. — P. 234–241.
- [8] Going deeper with convolutions / Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent

Vanhoucke, Andrew Rabinovich // ArXiv. — 2014. — Access mode: <https://arxiv.org/pdf/1409.4842.pdf>

[9] Deep Learning for Identifying Metastatic Breast Cancer / D. Wang, A. Khosla, R. Gargeya, H. Irshad, and A. H. Beck. // ArXiv. —2016. — Access mode: <https://arxiv.org/pdf/1606.05718.pdf>

[10] Rethinking the Inception Architecture for Computer Vision / Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens // ArXiv. —2015. — Access mode:<https://arxiv.org/pdf/1512.00567.pdf>

[11] Deep Residual Learning for Image Recognition / Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun // ArXiv. —2015. — Access mode: <https://arxiv.org/pdf/1512.03385.pdf>

[12]Health National Institutes. NIH Chest X-rays. — 2017. — Access mode: <https://www.kaggle.com/nih-chest-xrays/data>

[13] Caffe. Deep learning framework. — Access mode: <http://caffe.berkeleyvision.org>