

ПРАВИТЕЛЬСТВО РОССИЙСКОЙ ФЕДЕРАЦИИ
ФГАОУ ВО НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ УНИВЕРСИТЕТ
«ВЫСШАЯ ШКОЛА ЭКОНОМИКИ»

Факультет компьютерных наук
Образовательная программа «Прикладная математика и информатика»

Отчет о программном проекте на тему:
Разработка методов, алгоритмов и приложения распознавания различных видов
ран на теле человека по снимку

Выполнил студент:

группы #БПМИ211, 3 курса

Пономарчук Анна Сергеевна

Принял руководитель проекта:

Молодченков Алексей Игоревич

Научный сотрудник

Федеральное государственное учреждение "Федеральный исследовательский
центр "Информатика и управление" Российской академии наук"

Содержание

Аннотация	3
1 Введение	4
1.1 Описание предметной области	4
1.2 Цель работы	4
2 Обзор литературы	5
2.1 Анализ изображений	5
2.2 Классификация изображений	5
2.3 Сегментация изображения	6
3 Классификация пролежней по стадиям	7
3.1 Пролежни	7
3.2 Датасет PИИД	8
3.3 Подготовка к экспериментам	9
3.4 Обучение базовой модели	10
3.5 Подбор гиперпараметров	11
3.6 Результаты	12
4 Создание приложения для классификации пролежней по изображениям	13
5 Сегментация пролежней	14
6 Заключение	15
Список литературы	18

Аннотация

В данной работе описывается разработка методов, алгоритмов и приложения распознавания различных видов ран на теле человека по снимку и их классификации по стадиям.

Ключевые слова

Глубинное обучение, анализ изображений, классификация изображений, сегментация изображений

1 Введение

1.1 Описание предметной области

Раны - это механические повреждения на теле, которые сопровождаются нарушением целостности тканей и характеризуются болью, воспалением и нередко кровотечением. Каждая рана от момента появления на теле до полного её заживления проходит три стадии: первую, во время которой организм избавляется от инородных тел и уже нежизнеспособных тканей, вторую, во время которой рана уменьшается и наполняется клеточным матриксом, и третью, которая характеризуется окончательным формированием рубца на коже и полным закрытием раны. Поскольку раной можно считать практически любое повреждение - начиная от небольшой ссадины, заканчивая глубоким поражением кожных покровов, требующим немедленного врачебного вмешательства, - можно смело назвать раны самыми частыми травматическими повреждениями человека. Однако, несмотря на это, на данный момент в публичном доступе нет ни одного инструмента, позволяющего определять тип раны или её стадию (и уж тем более какие-либо её характеристики вроде глубины или степени инфицированности) на основании изображения.

1.2 Цель работы

Цель данной работы - разработать методы и алгоритмы, которые позволят не только эффективно определять тип раны по её изображению, но также и анализировать её глубину, инфицированность и, возможно, другие не менее важные показатели, которые значительно влияют на скорость и возможность самостоятельного заживления ран. Создание такого инструмента упростит процедуры диагностики и лечения ран, а также с большой долей вероятности поможет избежать постановки ошибочных диагнозов, главной причиной которых чаще всего становится человеческий фактор.

Поскольку данная работа рассчитана на два года, то в этом году главной целью стало создание инструмента для определения стадии раны по её изображению. В качестве ран для исследования были выбраны пролежни, поскольку в открытом доступе есть качественный датасет с их изображениями. Целью работы в следующем году станет разработка метода для сегментации раны для определения степени её инфицированности, а также разработка алгоритма для проведения измерений таких параметров как глубина раны, её ширина и так далее.

2 Обзор литературы

2.1 Анализ изображений

С каждым годом появляется всё больше областей, в которых для анализа изображений применяется глубинное обучение. В статье Сикорского О. С. [8] описаны архитектуры нескольких нейронных сетей, которые продемонстрировали отличное качество в задаче классификации изображений, а также проанализированы результаты их работы. К таким нейронным сетям относятся, например, AlexNet, VGGNet и ResNet, каждая из которых может быть успешно использована в настоящее время для анализа изображений в различных областях.

Глубинное обучение уже успешно применяется и в анализе медицинских изображений: в статье [6] детально описано, как применять глубинное обучение для локализации объектов на медицинских изображениях, включая снимки, полученные при помощи магнитно-резонансной томографии, компьютерной томографии, рентгенографии и рентгеноскопии, обнаружения анатомических структур, сегментации тканей и диагностики, а также прогнозирования различных заболеваний. Ещё в одной статье [2] проанализированы возможные способы использования глубинного обучения для выявления диабетической ретинопатии, болезни Альцгеймера на ранней стадии и некоторых других заболеваний по медицинским снимкам.

2.2 Классификация изображений

Одной из ключевых задач анализа медицинских изображений остаётся задача классификации, то есть определения категории объекта, изображённого на фотографии. В зависимости от поставленной задачи может понадобиться как определить категорию одного объекта, который представлен на изображении, так и нескольких. Решение задачи классификации ран, к примеру, может позволить определять стадии их заживления, что позволит медицинским работникам эффективнее контролировать этот процесс. Данная задача рассматривается в статье [1] на примере пролежней - повреждений кожи, возникающих из-за плохого кровообращения, которое обусловлено давлением в области раны. В статье рассматривается несколько архитектур свёрточных нейронных сетей и проводятся эксперименты, демонстрирующие, что многие предобученные нейронные сети способны хорошо классифицировать медицинские изображения.

Для проведения экспериментов авторы статьи используют датасет PИИD (Pressure

Injury Images Dataset), который был создан ими в рамках этого исследования. Каждое из изображений, которые в него включены, было классифицировано независимо двумя специалистами по стадиям в соответствии с протоколом EPUAP конференции [4] - от первой, которая считается самой лёгкой стадией, до четвёртой, которая характеризуется некрозом тканей вокруг и внутри раны. В датасете представлено от 230 до 313 изображений пролежней каждой стадии, что делает его достаточно сбалансированным для качественного обучения нейросети, что подтверждают проведённые авторами многочисленные эксперименты и построенные по их результатам матрицы ошибок.

2.3 Сегментация изображения

Не менее важной задачей является задача сегментации медицинского снимка раны. Она позволяет не только оценивать площадь задетых кожных покровов (что особенно актуально для обширных ран), но и распознавать возможные инфекции. Один из методов решения этой задачи описан в статье [5], авторы которой предложили алгоритм для сегментации изображения раны и определения наличия инфекции после хирургических операций по снимку на основе метода опорных векторов. Разработанный ими алгоритм позволяет определять места, на которые наложены швы, а также с точностью выше 80% обнаруживать признаки инфекции в ране.

Для проведения экспериментов авторами статьи был собран датасет из 293 изображений ран, которые им предоставили отделения хирургии и внутренней медицины больницы Национального Тайваньского университета. Важным отличием от датасета PИИД помимо характера самих ран является то, что фотографии для данного исследования были намеренно сделаны на разные устройства, с разных углов при разном уровне освещения, что позволяет ожидать того качества, которого смогли добиться авторы статьи, от анализа снимков, сделанных вне данного исследования.

Другой метод решения данной задачи описан в статье [3], авторы которой разработали метод для сегментации ран лабораторных мышей, выделения, собственно, раны, её краёв и поражённых участков, а также измерения размеров раны и степени её заживления по фотографиям. Алгоритм сегментации ран, разработанный авторами данной статьи, базируется на двух других известных алгоритмах - YOLO (для обнаружения объектов) и U-Net (для сегментации медицинских объектов). Для оценки размера раны и степени её заживления по изображению авторами был разработан новый алгоритм, который выделял саму рану и внутреннюю область шины, расположенной вокруг раны, и проводил необходимые

вычисления.

Несмотря на то что используемый авторами датасет содержит всего 256 изображений, полученные после проведения экспериментов результаты позволяют считать, что с поставленной задачей алгоритм справился не хуже экспертов, которые делали соответствующие измерения независимо друг от друга. Кроме того, авторы статьи утверждают, что полученных результатов можно добиться и при применении данного метода к изображениям ран на телах людей.

Авторы ещё одной статьи [7] на основе MobileNetV2 создали фреймворк, позволяющий сегментировать раны, в частности язвы, на изображениях стоп и провели несколько экспериментов, демонстрирующих успешность такого подхода.

Авторы данной статьи также создали свой датасет, который включает 1109 изображений стоп с язвами. Изображения в данном датасете также были сделаны на разных фонах при разном уровне освещённости с разным разрешением. Кроме того, полученные изображения были разных размеров, поскольку в дальнейшем 1109 фотографий, сделанных авторами статей были объединены с фотографиями, сделанными докторами, и итоговая модель обучалась на 3645 изображениях и тестировалась на 405 снимках. Разметка данных была проведена авторами статьи и докторами полностью вручную, поскольку модель должна была обучиться тому, как человек-эксперт распознаёт рану.

3 Классификация пролежней по стадиям

3.1 Пролежни

Пролежни - это язвы, которые возникают в результате давления собственной массы пациента на кожные покровы. На данный момент из-за очень высокой стоимости лечения пролежни являются одной из главных проблем всемирного здравоохранения и выступают важнейшим показателем качества оказания помощи в больнице. В соответствии с протоколом EPUAP (European Pressure Ulcer Advisory Panel) конференции [4] пролежни делятся на четыре стадии: на первой стадии кожные покровы не повреждены, однако в месте пролежня кожа красная и остаётся такой даже после снятия давления, на второй стадии верхний слой кожи в месте язвы значительно повреждён и открыт, третья стадия характеризуется распространением повреждения на жировую ткань, из-за чего в месте повреждения часто присутствуют мёртвые ткани, четвёртая стадия - самая тяжёлая - относится к глубоким ранам, а повреждения достигают мышечной ткани и могут обнажить сухожилия или даже

кости. Фотографии пролежней всех четырёх стадий представлены на Рисунке 3.1.



Рис. 3.1: Примеры фотографий пролежней различных стадий. Самое левое изображение соответствует пролежню первой стадии, следующее за ним - второй, затем - третьей, правое изображение - четвёртой.

В зависимости от стадии пролежня пациенту требуется различное лечение: на ранних стадиях достаточно бережного очищения кожи и перевязок, на более поздних необходимо операционное вмешательство с дальнейшим мониторингом процесса заживления. Для определения стадии пролежня врачам необходимо измерять множество параметров, включающих, например, площадь раны, главную и малую диагонали. Все эти измерения, а также дальнейший мониторинг процесса заживления на данный момент проводятся инвазивно, что причиняет пациентам дискомфорт и боль. Именно поэтому создание инструмента, позволяющего по фотографии определять стадию пролежня, является крайне важной задачей, решение которой способно избавить пациентов от страданий.

Главная сложность решения задачи классификации пролежней по стадиям заключается в том, что время от времени даже специалисты некорректно определяют стадию раны. Эта проблема наглядно демонстрируется в статье [4], в которой представлена таблица с результатами голосования экспертов, к какой стадии относятся пролежни, изображенные на фотографиях. Так, к примеру, большинство экспертов отнесли изображение пролежней второй стадии к пролежням третьей стадии.

3.2 Датасет PIID

Поскольку в процессе решения задач, связанных с медицинскими изображениями, остро стоит этический вопрос фотографирования больных, в процессе выполнения данной работы было принято решение работать с датасетом PIID (Pressure injury images dataset), который уже упоминался выше. Данный датасет содержит 1091 медицинское изображение пролежней размера 229×229 . Изображения были сделаны в региональной учебно-исследовательской больнице Эрзурума (Турция) в период с марта 2018 года по январь 2021.

Датасет включает изображения пролежней у пациентов обоих полов в возрасте от 50 до 88 лет, цвет кожи которых также различен. Кроме того, важным преимуществом данного

датасета является наличие в нём изображений пролежней, расположенных на разных частях тел - начиная от головы, заканчивая пятками.

Тем не менее в данном датасете есть существенный недостаток, который заключается в том, что в нём отсутствуют фотографии кожи людей, у которых нет пролежней, а также изображения других ран. Это не влияет на эксперименты, которые проводились авторами статьи, однако мешает обобщению результатов на фотографии не из датасета P1D, поскольку любая модель будет классифицировать фотографию, на которой пролежней нет, как некоторую стадию такой раны, что приведёт к нежелательным последствиям. Кроме того, несмотря на то, что авторы статьи утверждают, что фотографии делались в различных условиях, при подробном изучении датасета стало очевидно, что на подавляющем большинстве фотографий одинаковый угол съёмки, одинаковая степень освещённости, одинаковые устройства съёмки. Из-за этого для того, чтобы модель умела классифицировать изображения не из датасета, нужно применять сложные аугментации, но даже это не гарантирует сохранение полученного авторами статьи качества на новой тестовой выборке. Эту проблему решит расширение датасета путём добавления новых изображений, которые мы совместно с сотрудниками Федерального государственного учреждения "Федеральный исследовательский центр "Информатика и управление" Российской академии наук" планируем получить от сотрудников московских больниц.

3.3 Подготовка к экспериментам

Как уже упоминалось выше, в датасете содержится всего 1091 медицинское изображение, поэтому важно было решить, в каком соотношении разделить исходную выборку на обучающую и тестовую. Было проведено более 70 экспериментов, результаты которых продемонстрировали, что качество, получаемое при тестировании модели на 10% изображений, не стабильно. При этом при увеличении их числа до 15% всех фотографий результаты стабилизируются. Именно поэтому было принято решение разделить исходную выборку на обучающую и тестовую в соотношении 85 : 15. Таким образом, в обучающей выборке оказалось 928 изображений, а в тестовой - 163 (из них 36 изображений пролежней первой стадии, 40 - второй, 49 - третьей и 38 - четвёртой). В качестве метрики качества использовались как значение ассигасу (число изображений, для которых были корректно предсказаны классы делённое на число всех изображений), так и матрицы ошибок. Эти метрики позволяют сравнивать качество обученной модели с качеством моделей из статьи [1].

Наилучшее качество, которого удалось добиться авторам статьи [1], - 77.42%, на Ри-

сунке 3.2 представлены значения ассигасы и матрицы ошибок для моделей, значение ассигасы на которых превысило 70%. Нетрудно заметить, что главную сложность у всех обученных моделей вызывает идентификация третьей стадии пролежни, а корректность определения остальных стадий не превышает 90%.

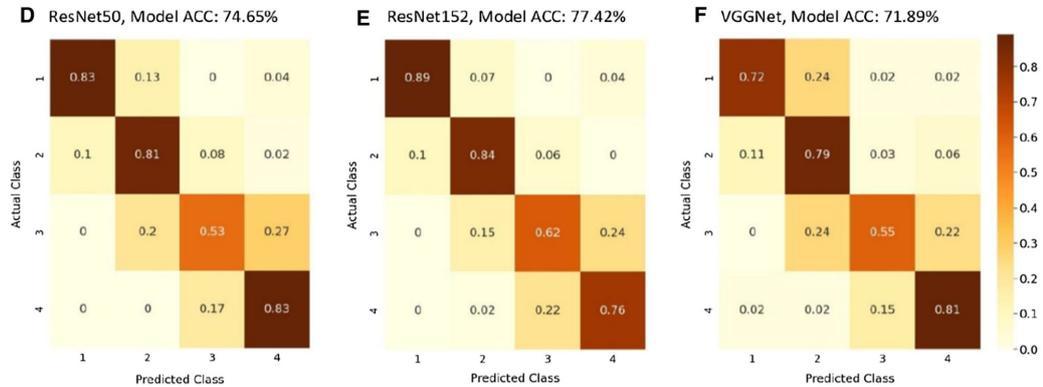


Рис. 3.2: Значения ассигасы и матрицы ошибок для соответствующих моделей.

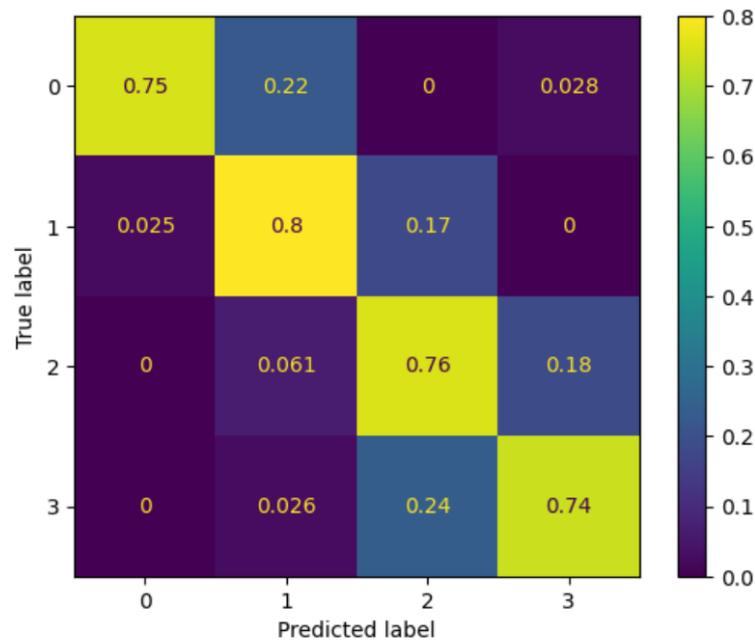
Для того, чтобы получить больше изображений для обучения модели, а также для дальнейшего обобщения полученных результатов на пролежни, сфотографированные в других условиях (то есть с иным углом съёмки, при другом освещении), к изображениям из обучающей выборки были применены следующие аугментации: отражение по горизонтали (RandomHorizontalFlip) с вероятностью 0.5, поворот на 10° (RandomRotation), а также изменение некоторых параметров изображения (ColorJitter). В частности, были установлены следующие параметры: brightness = 0.2 (яркость изображения), contrast = 0.2 (контрастность изображения), saturation = 0.2 (насыщенность изображения), hue = 0.05 (оттенок изображения).

3.4 Обучение базовой модели

Чтобы выбрать модель, с использованием которой в процессе выполнения курсовой работы будут проводиться эксперименты, было решено использовать несколько предобученных моделей (AlexNet, ResNet50, ResNet152, VGG16). Во все предобученные модели загружались веса по умолчанию, и все модели дообучались 20 эпох. В качестве оптимайзера использовался Adam, в который передавались model.parameters().

Лучший результат, полученный в процессе дообучения AlexNet, представлен на Рисунке 3.3, в процессе дообучения ResNet50 - на Рисунке 3.4, в процессе дообучения ResNet152 - на Рисунке 3.5, в процессе дообучения VGG16 - на Рисунке 3.6.

Каждый из этих результатов оказался лучше, чем результаты, полученные в статье, и



Epoch: 16
 train accuracy: 0.8642241379310345
 test accuracy: 0.796875

Рис. 3.3: Результат дообучения модели AlexNet.

благодаря применённым к обучающей выборке аугментациям можно ожидать, что качество на новых изображениях будет также достаточно высоким.

После анализа полученных результатов было принято решение продолжать работать с ResNet50, так как данная модель продемонстрировала лучший результат. В процессе проведения экспериментов предпринимались попытки изменить оптимайзер на SGD, а также Adagrad и Adamax с различными гиперпараметрами, однако это привело только к снижению качества модели, поэтому было решено в дальнейшем также использовать оптимайзер Adam.

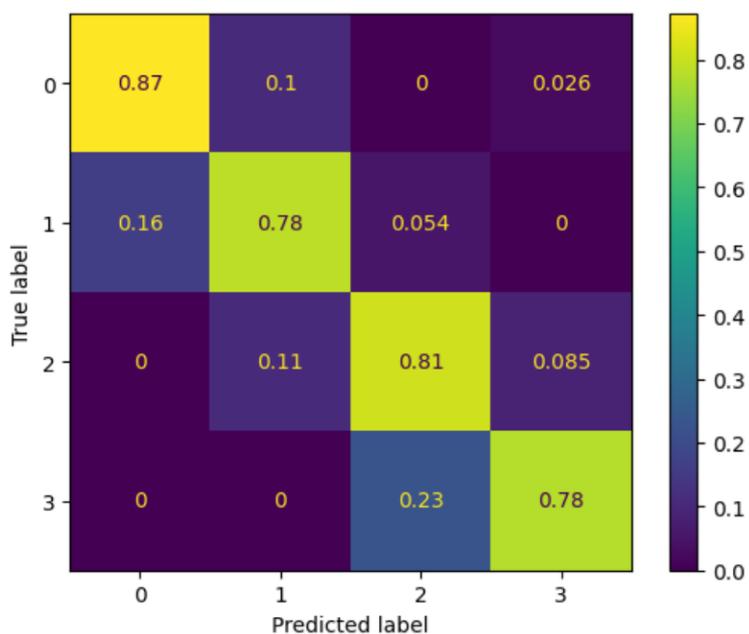
3.5 Подбор гиперпараметров

Для начала было решено подобрать гиперпараметры для оптимайзера Adam. Начать было решено с темпа обучения learning rate, значения которого перебирались от 0.0005 до 0.01 с шагом 0.0005. Лучшего результата удалось добиться для значения lr= 0.0085, были получены метрики, указанные на Рисунке 3.7.

Кроме того, предпринимались попытки подобрать оптимальные значения гиперпараметров weight_decay и eps, однако значения метрик оставались на том же уровне или становились ниже.

Следующим успешным экспериментом стала разморозка последнего линейного слоя классификации модели ResNet50, результат представлен на Рисунке 3.8.

В процессе выполнения курсовой работы было проведено ещё множество эксперимен-



Epoch: 4
train accuracy: 0.9213362068965517
test accuracy: 0.8385416666666666

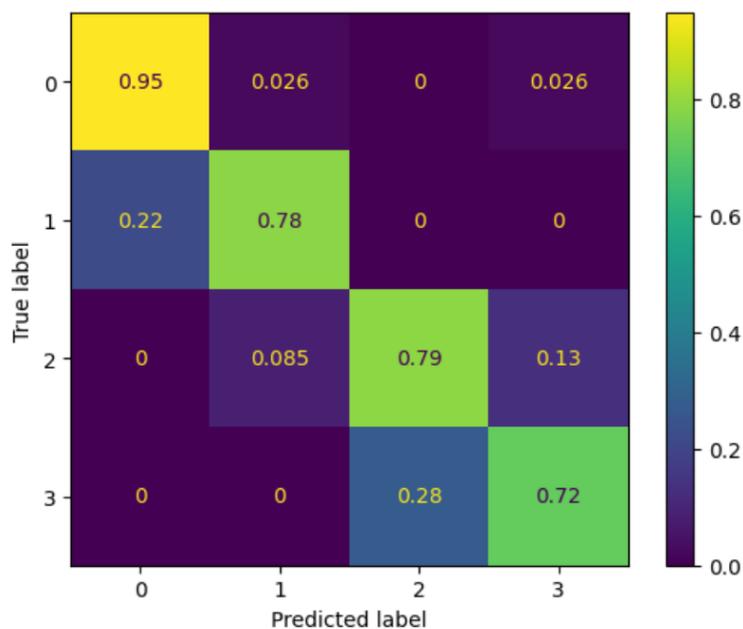
Рис. 3.4: Результат дообучения модели ResNet50.

тов, суммарная длительность которых составляет приблизительно 300 часов. К сожалению, увеличить качество, полученное в результате последнего описанного эксперимента, так и не удалось. Тем не менее, поставленная цель была достигнута.

3.6 Результаты

Таким образом, удалось обучить модель, которая на тестовой выборке демонстрирует качество 86.458%, что на 9% лучше модели, обученной авторами оригинальной статьи. Кроме того, данная модель практически безошибочно определяет самый опасный для жизни пациента класс - четвертую стадию пролежней. Кроме того, модель уверенно классифицирует первую и вторые стадии пролежней, намного лучше, чем модели, обученные авторами статьи.

Как уже неоднократно говорилось, нельзя с уверенностью утверждать, что на изображениях, отличных от тех, которые присутствуют в датасете, качество предсказаний окажется настолько же высоким. Однако если расширить датасет, добавив в него больше изображений, которые сделаны в иных условиях, вполне вероятно данная модель, обучившись на новых данных, сможет также хорошо предсказывать стадии пролежней, изображённых уже на новых фотографиях.



Epoch: 18
train accuracy: 0.927801724137931
test accuracy: 0.7881944477558136

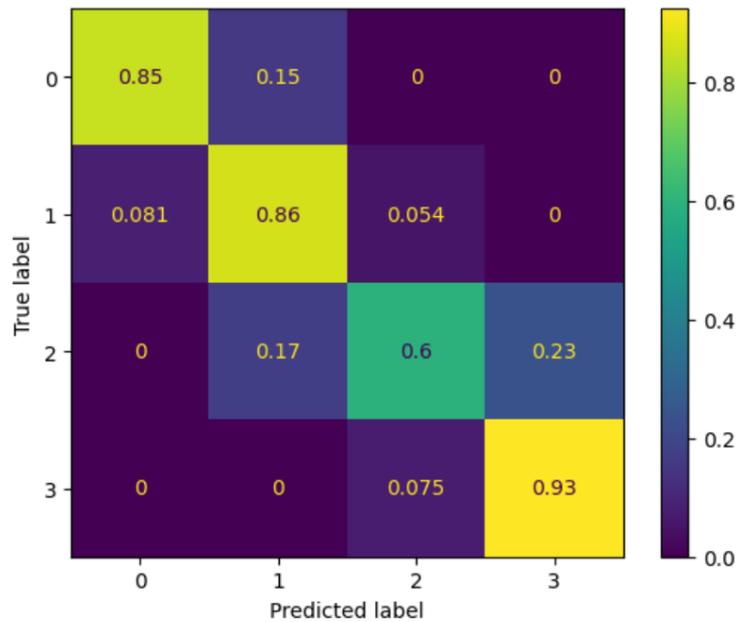
Рис. 3.5: Результат дообучения модели ResNet152.

4 Создание приложения для классификации пролежней по изображениям

Следующим важным этапом решения поставленной задачи стало создание приложения. В результате выполнения данной курсовой работы был написан класс для работы с изображениями и предсказания стадии пролежня при помощи обученной модели, который был имплементирован в приложение, разработкой интерфейса которого занимались сотрудники Российской академии наук.

Написанный класс Model содержит методы `load_model`, в который передаётся полный путь до предобученной модели в формате `.pkl`, `predict`, в который передаётся полный путь до изображения и который возвращает число от 1 до 4 - стадию пролежня, изображённого на изображении, а также функцию `get_image`, которая обрезает изображение до нужного размера 229×229 , преобразует его в нормализованный тензор, а также добавляет переданное изображение в датасет - это нужно для того, чтобы в дальнейшем добавить функцию определения стадий пролежней, изображенных сразу на нескольких фотографиях. Как известно, полный путь к файлу в Windows отличается от полного пути к файлу в большинстве других операционных систем, методы отлично работают с каждым из них.

Для получения результата необходимо запустить метод `load_model`, передав ему полный путь до предобученной модели в формате `.pkl`, а затем запустить метод `predict`, передав



Epoch: 16
train accuracy: 0.834051724137931
test accuracy: 0.828125

Рис. 3.6: Результат дообучения модели VGG16.

в него полный путь до изображения, стадию пролежня на котором нужно определить.

Стоит отметить, что поскольку приложение предназначено для использования пациентами и докторами, для работы не требуется GPU. Этого удалось добиться благодаря использованию класса `CPU_Unpickler`, позволяющего загружать модель даже без доступа к графическому процессору.

5 Сегментация пролежней

Следующим этапом работы стала сегментация изображений пролежней из датасета РИД. Главной целью было проверить, подходят ли наиболее известные модели для сегментации изображений пролежней. Поскольку в дальнейшем планируется научиться измерять отдельные параметры раны, такие как её ширина и глубина, а также степень инфицированности, сегментация необходима.

Для начала было принято решение протестировать, насколько хорошо способны предобученные модели выделять рану. Для экспериментов были использованы реализация U-Net в PyTorch для Kaggle's Carvana Image Masking Challenge и Segment Anything. Реализация U-Net, к сожалению, не сумела достаточно качественно выделить рану на изображении пролежня четвёртой стадии (результаты сегментации продемонстрированы на Рисунке 5.1). Это, вероятно, связано с тем, что данная модель обучалась на изображениях очень высокого

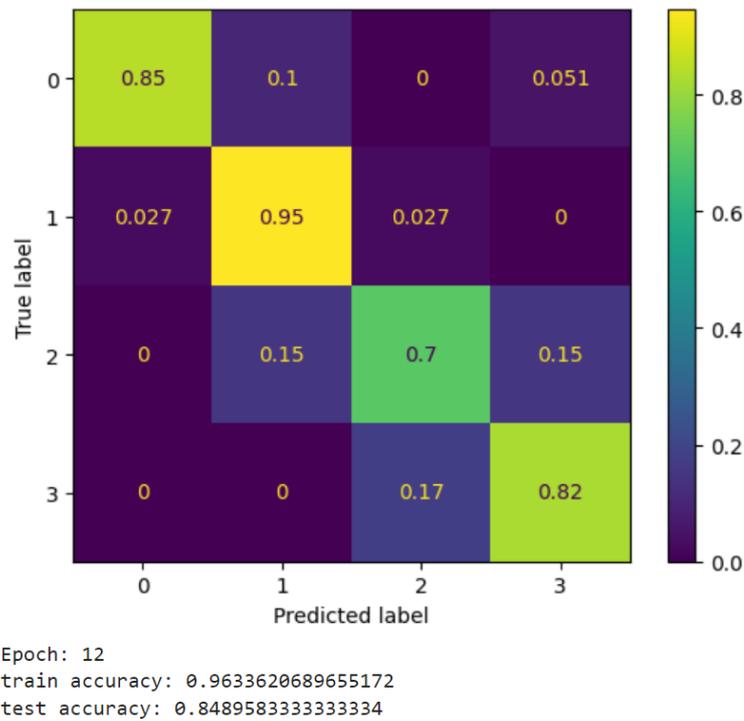


Рис. 3.7: Результат дообучения модели ResNet50 с оптимайзером Adam, значение $lr = 0.0085$.

качества, намного выше, чем качество фотографий из датасета P11D.

Результаты, полученные при помощи Segment Anything, оказались намного лучше. Результат применения модели Segment Anything к тому изображению, с которым не справилась модель U-Net, изображен на Рисунке 5.2. После проведения нескольких экспериментов был сделан вывод, что модель Segment Anything способна отлично сегментировать раны, выделяя не только её края, но и отдельные объекты внутри раны (например, мёртвые ткани, гной или кости).

Таким образом, сегментацию изображений пролежней из датасета P11D для дальнейшей работы можно провести при помощи Segment Anything. Тем не менее, поскольку работа в этом направлении только началась, требуется провести ещё немало экспериментов, чтобы убедиться в том, что результаты сегментации действительно удовлетворяют поставленным задачам.

6 Заключение

Таким образом, в процессе выполнения данной курсовой работы были изучены релевантные статьи, изучена система классификации пролежней по четырём стадиям, было проведено множество экспериментов для обучения модели классификации (число проведённых экспериментов - приблизительно 1000). В результате была получена модель, классифициру-

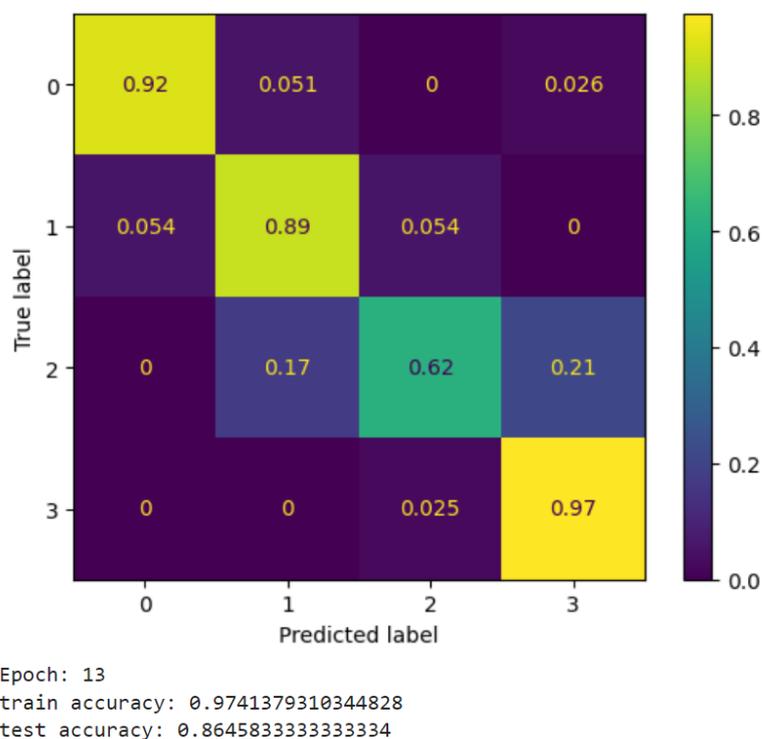


Рис. 3.8: Результат дообучения модели ResNet50 с оптимайзером Adam, значение $lr=0.0085$, последний линейный слой классификации модели ResNet50 разморожен.

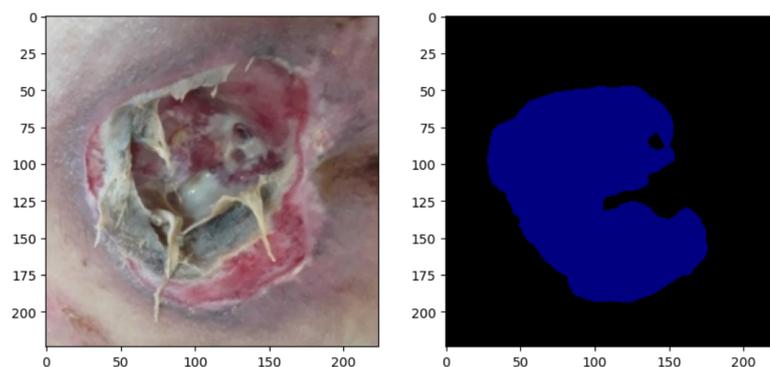


Рис. 5.1: Результат сегментации изображения при помощи U-Net.

ющая пролежни по четырём стадиям с точностью 86.458%, что на 9% выше, чем точность лучшей из известных на данный момент моделей, решающих ту же задачу. Затем полученная модель была имплементирована в приложение, которым могут пользоваться как пациенты, так и доктора.

В дальнейшем планируется подробнее изучить сегментацию изображений, а также разработать алгоритмы для определения параметров ран, изображённых на фотографиях (в частности, их глубины, ширины, инфицированности). Кроме того при помощи докторов из московских больниц планируется расширить датасет PИИД, который использовался в процессе выполнения курсовой работы, для улучшения полученных результатов.

Стоит отметить, что результаты, полученные в процессе выполнения данной курсовой



Рис. 5.2: Результат сегментации изображения при помощи модели Segment Anything.

работы, будут использованы для написания выпускной квалификационной работы.

Список литературы

- [1] Betul Ay, Beyda Tasar, Zeynep Utlu, Kevser Ay и Galip Aydin. “Deep transfer learning-based visual classification of pressure injuries stages”. В: *Neural Computing and Applications* 34 (2022), с. 16157—16168.
- [2] Lei Cai, Jingyang Gao и Di Zhao. “A review of the application of deep learning in medical image classification and segmentation”. В: *Annals of Translational Medicine* 8.11 (2020), с. 713—728.
- [3] Héctor Carrión, Mohammad Jafari, Michelle Dawn Bagood, Hsin-ya Yang, Roslyn Rivkah Isseroff и Marcella Gomez. “Automatic wound detection and size estimation using deep learning algorithms”. В: *PLoS Computational Biology* 18.3 (2022).
- [4] Laura E. Edsberg, Joyce M. Black, Margaret Goldberg, Laurie McNichol, Lynn Moore и Mary Siegreen. “Revised National Pressure Ulcer Advisory Panel Pressure Injury Staging System”. В: *Journal of Wound, Ostomy and Continence Nursing* 43.6 (2016), с. 585—597.
- [5] Jui-Tse Hsu, Yung-Wei Chen, Te-Wei Ho, Hao-Chih Tai, Jin-Ming Wu, Hsin-Yun Sun, Chi-Sheng Hung, Yi-Chong Zeng, Sy-Yen Kuo и Feipei Lai. “Chronic wound assessment and infection detection method”. В: *BMC Medical Informatics and Decision Making* 19.99 (2019).
- [6] Dinggang Shen, Guorong Wu и Heung-Il Suk. “Deep Learning in Medical Image Analysis”. В: *Annual Review of Biomedical Engineering* 19 (2017), с. 221—248.
- [7] Chuanbo Wang, D. M. Anisuzzaman, Victor Williamson, Mrinal Kanti Dhar, Behrouz Rostami, Jeffrey Niezgod, Sandeep Gopalakrishnan и Zeyun Yu. “Fully automatic wound segmentation with deep convolutional neural networks”. В: *Scientific Reports* 10.21897 (2020).
- [8] Сикорский О.С. *Обзор свёрточных нейронных сетей для задачи классификации изображений*. URL: <https://cyberleninka.ru/article/n/obzor-svyortochnyh-neyronnyh-setey-dlya-zadachi-klassifikatsii-izobrazheniy/viewer> (дата обр. 01.02.2024).