

УДК 004.93

Черняк К.Е., Лукьянова Н.А., Голденок Е.Е.

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В ЗАДАЧЕ КЛАССИФИКАЦИИ МРТ-ИЗОБРАЖЕНИЙ КОЛЕННОГО СУСТАВА

Красноярский государственный медицинский университет имени профессора В. Ф. Войно-Ясенецкого, г. Красноярск

Остеоартрит коленного сустава является одним из самых распространенных заболеваний опорно-двигательного аппарата, сопровождающийся постепенным разрушением тканей сустава. На сегодняшний день не существует эффективного лечения этого заболевания, что делает раннюю диагностику ключевым моментом в управлении этим заболеванием. В рамках данного исследования решается задача бинарной классификации для определения наличия признаков остеоартрита коленного сустава на МРТ изображении с использованием сверточных нейронных сетей. Для достижения этой цели на изображениях здоровых и поврежденных коленных суставов пациентов Красноярского края были обучены и протестированы две модели с использованием современных архитектурных решений, EfficientNet-B5 и VGG16. На этапе предобработки данных рабочий набор снимков (1904 изображения) был увеличен за счет метода аугментации до 3500 снимков и решена проблема дисбаланса классов, что позволяет рассматривать accuracy (доля правильных ответов модели), как метрику качества работы алгоритма. Наилучшие результаты показала модель, основанная на архитектуре EfficientNet-B5, достигнув точности классификации в 92,0% на тестовой выборке и 92,3% на валидационной выборке. Эти результаты свидетельствуют о потенциале использования нейронных сетей для автоматизации диагностики остеоартрита по МРТ изображениям коленного сустава.

Ключевые слова: машинное обучение, сверточная нейронная сеть, МРТ изображения, остеоартрит коленного сустава.

Ввиду своей широкой распространенности, дегенеративно-дистрофические поражения суставов (остеоартроз/остеоартрит – ОА) представляют собой серьезную медико-социальную проблему во многих странах мира, включая Россию. По данным [1,3] остеоартрит поражает 12% населения РФ. Более того, показатели заболеваемости продолжают демонстрировать тенденцию к росту, в связи с чем особенно актуальным представляется поиск новых подходов к предотвращению прогрессирования данной группы заболеваний и методов наиболее эффективной диагностики. Постановкой диагноза занимаются высококвалифицированные специалисты, но с развитием информационных технологий, в том числе методов машинного обучения, существует возможность автоматизированного скрининга ОА по МРТ изображениям коленного сустава. Поэтому, актуальной задачей является корректная автоматизированная диагностика повреждения коленных суставов с использованием сверточных нейронных сетей, способных работать в условиях ограниченных вычислительных ресурсов и обладающих высокой точностью распознавания.

Искусственные нейронные сети – это вычислительные аналитические инструменты, вдохновленные биологической нервной системой. Они состоят из сетей сильно взаимосвязанных компьютерных процессоров, называемых «нейронами», которые способны выполнять параллельные вычисления для обработки данных и представления знаний [6]. Их способность учиться на исторических примерах, анализировать нелинейные данные,

обрабатывать неточную информацию и обобщать, сделала их очень привлекательным аналитическим инструментом в области медицины [4].

В работе [10] исследовательская группа создала модель оценки размера суставной щели. Для врачей клиницистов подобный параметр служит биомаркером для оценки тяжести артрита в клинических условиях. В работе использовался алгоритм глубокого обучения анализа изображений методом парной двухэнергетической рентгеновской абсорбциометрии. Это исследование отражает более широкий интерес к тому, как искусственный интеллект может быть использован для улучшения медицинской визуализации [7,8,9,11,12].

Также при создании нейронных сетей используются сети U-net. Анализ трехмерной магнитно-резонансной томографии полезен для измерения хряща и мениска у пациентов с остеоартритом коленного сустава. Проблемы ручной сегментации были решены путем разработки автоматических методов сегментации с использованием глубоких нейронных сетей, а использование искусственного интеллекта и метода глубокого обучения для измерения высоты надколенника [2,6].

Цель работы

Цель работы – создание математической модели бинарной классификации МРТ-изображений для диагностики повреждения коленного сустава.

Для достижения цели были поставлены и решены следующие задачи.

1. Провести предобработку и препроцессинг реальных цифровых изображений коленных суставов пациентов Красноярского края.
2. Создать классификационные модели на основе известных архитектур сверточных нейронных сетей EfficientNet-B5 и VGG16, исследовать их применимость.
3. Оценить качество работы построенных моделей классификации.

Материал и методы

Материалом исследования является собранный набор реальных МРТ-изображений, предоставленных для исследования частной медицинской организацией ООО «ЛДЦ МИБС» г. Красноярска. Все изображения были предварительно деперсонализированы врачом-рентгенологом, который выступил в качестве эксперта при разметке снимков на два класса: класс 0 (Healthy) – изображение здорового колена; класс 1 (Severe) – тяжелое повреждение колена, включающее крупные остеофиты, значительное сужение суставов и тяжелый склероз. На данном исследовании используется 1904 снимков, из которых в класс 0 (Healthy) определен 551 снимок с изображением здорового коленного сустава, 1353 снимков отнесено к классу 1 (Severe).

Методы исследования. На этапе препроцессинга потребовалось изменить DICOM формат изображений в JPEG и провести масштабируемость до рабочего размера 224 x 224 пикселей (рис. 1). Для этого использовалась приложение Total Image Converter.

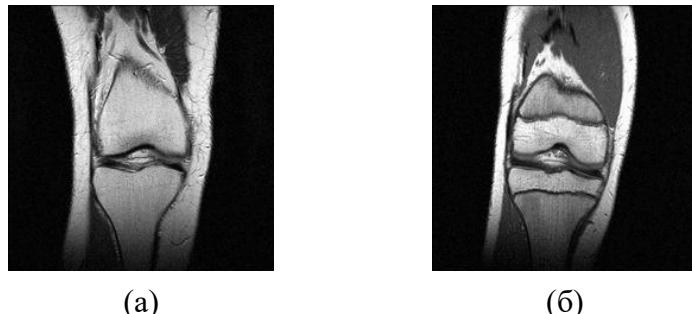


Рис. 1. Примеры обезличенных изображений суставов, размер 224 x 224 пикселей: (а) – неповрежденный коленный сустав, (б) - поврежденный коленный сустав

Причин для этого было несколько, во-первых, наборы снимков в DICOM формате занимают большой объем памяти и для обучения нейронной сети требуются высокие вычислительные возможности. Во-вторых, набор снимков пациентов Красноярского края будет в следующих работах объединен с наборами из открытых источников Kaggle по данной исследовательской проблеме, чтобы увеличить базу данных, поэтому необходима совместимость снимков по размеру.

В этом исследовании для преодоления проблемы недостаточности входных данных использовали метод увеличения выборки с помощью добавления трансформированных изображений (табл. 1). Метод аугментации заключается в применении к исходным данным разного рода преобразований, не меняющих основную информацию, содержащуюся на изображении, но слегка ее искажающих, что позволяет получить новые примеры на основе имеющихся.

Таблица 1

Решение проблемы недостаточности входных данных и дисбаланса классов

	Класс 0 – Healthy	Класс 1 – Severe	Объем набора изображений
Исходные данные	551	1353	1904
Аугментация	+1199	+397	+1596
Всего	1750	1750	3500

Далее, все собранные изображения подверглись рандомному разделению на три выборки: тестовую, тренировочную и валидационную, в соотношении 70:20:10 соответственно (табл. 2).

Таблица 2.

Разделение набора данных на три выборки (рандомно в соотношении 70:20:10)

Выборки:	Класс 0 – Healthy	Класс 1 – Severe	Количество снимков
Тренировочная (train, 70%)	1000	1000	2000
Тестовая (test, 20%)	600	600	1200
Валидационная (valid, 10%)	150	150	300
Всего	1750	1750	3500

Результаты и обсуждение

Задача бинарной классификации решалась с помощью построения сверточной нейронной сети на основе базовых моделей с архитектурами EfficientNet-B5 и VGG16, которые предобучены на базе ImageNet – наборе данных из более чем 14 миллионов изображений, принадлежащих к 1000 классам. При создании нейронной сети (модель 1) использовали архитектуру EfficientNet-B5. Благодаря своей архитектуре EfficientNet стал популярным выбором для решения задач классификации изображений на различных платформах с ограниченными ресурсами, так как он может достигать высоких результатов при небольшом объеме памяти и быстродействии. EfficientNet основан на идее компаунд-масштабирования, которое позволяет эффективно масштабировать глубину, ширину и разрешение модели, чтобы достигнуть оптимального баланса между точностью и вычислительной эффективностью. Модель EfficientNet состоит из 7 блоков, включающих в себя 16 сверточных слоев. В качестве функции активации используется ReLU, в последнем слое – Softmax. В архитектуре сети применяется метод Batch Normalization. Оптимизатором является Adam. Чтобы избежать переобучения, к последнему полносвязному слою применялась техника Dropout с параметром 0,3. К выходу последнего слоя (размером 2, по количеству классов), для получения вероятностей каждого из классов, применяется Softmax. При создании нейронной сети (модель 2) использована архитектура VGG16, как в работе [5], состоящая из 13 сверточных слоев и 4 полносвязных. В качестве функции активации используется ReLU, в последнем полносвязном слое – Sigmoid. Пространственное объединение осуществляется пятью объединяющими слоями (maxpooling). Оптимизатором является Adam. Обучение моделей осуществляли на 50 эпохах. Программная реализация нейронных сетей осуществлена на языке Python 3.9.1 с использованием программы Visual Studio Code 2019г.

Поскольку в работе решена проблема дисбаланса классов, то это позволяет рассматривать метрику accuracy, показывающую долю правильных ответов модели, как метрику качества работы алгоритма. Наилучшие результаты показала модель, основанная на

архитектуре EfficientNet-B5, достигнув точности классификации в 92,0% на тестовой выборке и 92,3% на валидационной выборке. В таблице 3 приведены оценки качества разработанных моделей.

Таблица 3

Сравнение моделей классификации

	Метрики на валидационной выборке	Support	Precision (%)	Recall (%)	F1-score (%)
Модель 1	Класс 0 - Healthy	150	95,4	89,3	92,1
	Класс 1 - Severe	150	89,9	95,3	92,6
	macro average (среднее)	300	92,5	92,3	92,3
		300	Accuracy (%) = 92,3		
Модель 2	Класс 0 - Healthy	150	96,6	38,0	54,5
	Класс 1 - Severe	150	61,4	98,7	75,7
	macro average (среднее)	300	79,0	68,3	65,12
		300	Accuracy (%) = 68,3		

* Модель 1 с базовой архитектурой EfficientNet-B5, модель 2 с базовой архитектурой VGG16

Сравнительный анализ полученных результатов обучения моделей с целью выявления наиболее точной модели для классификации рентгенологических снимков по признаку отсутствия или наличия ОА коленного сустава показал, что лучшей моделью является модель с архитектурой EfficientNet-B5.

Достоверность полученных результатов обеспечивается проведением серии экспериментов для каждой модели нейронной сети. В каждом из экспериментов исследуемые модели обучались на разных комбинациях подмножеств тренировочной и валидационной выборок, что позволяет обучать разные сети, не меняя при этом их структуры. Устойчивость результатов классификации обеспечивается усреднением результатов работы нескольких моделей.

Заключение и выводы

Использование нейронных сетей для классификации ОА коленного сустава не только повышает точность и скорость диагностики, но также способствует автоматизации и улучшению процесса работы рентгенологов, что является важным с точки зрения эффективности и качества здравоохранения. С учетом быстрого развития этой технологии, подобные подходы обещают перспективные результаты в будущем. Поэтому, продолжая работать в тематике данного исследования, авторы планируют исследовать применимость других архитектур нейронных сетей и оценить качество полученных моделей классификации на других базах данных по ОА коленного сустава из открытых источников для проверки сопоставимости результатов с другими исследователями.

ЛИТЕРАТУРА

1. Балабанова Р.М., Дубинина Т.В. Динамика пятилетней заболеваемости болезнями костно-мышечной системы и их распространенности среди взрослого населения России за 2013–2017 гг. // Современная ревматология. – 2019. – №13(4). С. 11–17.
2. Бруй Е.А., Владимиров Н.А. Нейросетевые решения на основе архитектуры u-net для автоматической сегментации хрящевой ткани лучезапястного сустава на мр изображениях // моделирование, оптимизация и информационные технологии. – 2021. – Т. 9. – № 2(33). – С. 1–9.
3. Жугрова Е.С., Беляева И.Б., Самигуллина Р.Р. Взгляд на остеоартрит с позиции доказательной медицины и собственного опыта // РМЖ. Медицинское обозрение. – 2023.– №7(3). – С. 167–173.
4. Зеленина, Л. И., Хаймина Л.Э., Деменкова Е.А. [и др.]. Сверточные нейронные сети в задаче классификации медицинских изображений // Современные научные технологии. – 2021. – №9. С.68–73.
5. Лукьянова Н.А., Потылицина С.Е. Применение сверточных нейронных сетей в задаче распознавания пневмонии // Информационные технологии и математическое моделирование (ИТММ-2022) : Материалы XXI Международной конференции имени А.Ф. Терпугова, Томск, 25–29 октября 2022 года. – Томск: НИ Томский гос. университет. – 2023. – С. 277-282.
6. Самойлов А.С., Голобородько Е.В. Ключников М.С. Большие данные, машинное обучение и прецизионное прогнозирование в спортивной медицине // Здравоохранение, образование и безопасность. – 2019. – № 1(17). – С. 7-17
7. Файзрахманов, А. Ф. [и др]. Машинное обучение в медицине: эволюция и перспективы // Южно-Сибирский научный вестник. – 2021. – № 4(38). – С. 43–49.
8. Aoki, Hayato, и др. Relationship between Medial Meniscus Extrusion and Cartilage Measurements in the Knee by Fully Automatic Three-Dimensional MRI Analysis // BMC Musculoskeletal Disorders. – 2020. - Т. 21. – С. 1–9.
9. Lee, Lok Sze, [и др]. Artificial intelligence in diagnosis of knee osteoarthritis and prediction of arthroplasty outcomes: a review // Arthroplasty. – 2022. – Т. 4. – С.16.
10. Sun, Limin, [и др]. Automatic Segmentation and Measurement on Knee Computerized Tomography Images for Patellar Dislocation Diagnosis // Computational and Mathematical Methods in Medicine. – 2020. – Т. 2020. – С. 1–13.
11. Si, Liping, и др. Deep Learning in Knee Imaging: A Systematic Review Utilizing a Checklist for Artificial Intelligence in Medical Imaging (CLAIM) // European Radiology. – 2022. – Т 32. – № 2. – С. 1–9.
12. Flynn, Brianna I. [и др]. Deep Learning Based Phenotyping of Medical Images Improves Power for Gene Discovery of Complex Disease // Npj Digital Medicine. – 2023. – Т. 6. – № 1. – С.1–12.