

**ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ВЫЯВЛЕНИЯ ПЕРЕЛОМОВ ПЛЕЧЕВОГО СУСТАВА
НА РЕНТГЕНОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКОГО ОБУЧЕНИЯ**

Утеулиев Ниетбай Утеулиевич – доктор физико-математических наук, профессор

Uteuoliiev@mail.ru

Джайков Гафур Муратбаевич – доктор технических наук, доцент

gafurdjaykov@gmail.com

Артыкбаев Жавлонбек Зиятбаевич – магистрант

artjavlon@gmail.com

Нукусский государственный технический университет

Сагидуллаев Нурсултан Ибадуллаевич – докторант

Ташкентский университет информационных технологий имени Мухаммада ал-Хоразми

**ChUQUR O‘RGANISH YORDAMIDA RENTGEN TASVIRLARIDA YELKA BO‘G‘IMI SINISHLARINI
ANIQLASHNING INTELLEKTUAL TIZIMI**

Uteuliev Nietbay Uteulievich – fizika-matematika fanlari doktori, professor

Djaykov Gafur Muratbaevich – texnika fanlari doktori, dotsent

Artikbaev Javlonbek Ziyatbay o‘g‘li – magistrant

Nukus davlat texnika universiteti

Sagidullaev Nursultan Ibadullaevich – doktorant

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti

**AN INTELLIGENT SYSTEM FOR DETECTING SHOULDER JOINT IN RADIOGRAPHIC
IMAGES USING DEEP LEARNING**

Uteuliev Nietbay Uteulievich – Doctor of Physical and Mathematical Sciences, Professor

Djaykov Gafur Muratbaevich – Doctor of Technical Sciences,

Associate Professor

Artikbaev Javlonbek Ziyatbaevichi – Master’s Student

Nukus State Technical University

Sagidullaev Nursultan Ibadullaevich – doctoral student

Tashkent University of Information Technologies

Таянч сўзлар: чукур ўрганиш, EfficientNet, рентген тасвирлари, синишлар, MURA, классификация.

Резюме. Ушбу мақолада EfficientNet-B0 асосида ёлка бўғими синишларини аниқловчи модель ишлаб чиқилади. Модель MURA (XR_SHOULDER) маълумотлар тўпламида ўқитилди. Натижада тахминан 80% аниқликка эришилди ва усул самарадорлиги тасдиқланди.

Ключевые слова: глубокое обучение, EfficientNet, рентгенография, переломы, MURA, классификация.

Резюме. В статье разработана модель автоматического выявления переломов плечевого сустава на рентгенографических изображениях с использованием архитектуры EfficientNet-B0. Обучение выполнено на подвыборке XR_SHOULDER датасета MURA. Достигнута точность около 80%, что подтверждает эффективность предложенного подхода.

Key words : deep learning, EfficientNet, radiography, fractures, MURA, classification.

Summary. This paper presents a deep learning-based model for automatic shoulder fracture detection using EfficientNet-B0. The model was trained on the XR_SHOULDER subset of the MURA dataset. The achieved accuracy of about 80% confirms the effectiveness of the proposed approach.

Введение. Заболевания и травмы плечевого сустава занимают значительное место в структуре повреждений опорно-двигательного аппарата и являются одной из частых причин обращения пациентов за медицинской помощью. Переломы проксимального отдела плечевой кости и повреждения суставных структур приводят к выраженному ограничению подвижности верхней конечности, снижению качества жизни пациентов и требуют своевременной и точной диагностики. Основным инструментом первичной визуализации остаётся рентгенография, однако интерпретация рентгенографических изображений плечевого сустава представляет собой сложную задачу вследствие анатомической сложности области, наложения костных структур и значительной вариабельности рентгенологических проекций [1].

В клинической практике диагностика переломов плечевого сустава традиционно основывается на

визуальной оценке рентгеновских снимков врачом-рентгенологом. Тем не менее даже при наличии достаточного опыта специалист может столкнуться с трудностями выявления маловыраженных переломов, особенно на ранних стадиях травмы или при неблагоприятных условиях визуализации. Рост объёма диагностических исследований и высокая нагрузка на медицинский персонал дополнительно повышают риск диагностических ошибок, что подчёркивает необходимость внедрения интеллектуальных систем поддержки принятия решений [2]. Развитие методов искусственного интеллекта и глубокого обучения открыло новые возможности для автоматизированного анализа медицинских изображений. Сверточные нейронные сети продемонстрировали высокую эффективность при решении задач классификации и обнаружения патологий на рентгенографических, компьютерно-томографических и магнитно-

резонансных изображениях [3, 4]. Использование предобученных архитектур и подхода transfer learning позволяет адаптировать модели к специфике медицинских данных даже при относительно ограниченном объёме обучающей выборки, что особенно актуально для узкоспециализированных клинических задач [5].

Одним из наиболее известных открытых наборов медицинских изображений является датасет MURA (Musculoskeletal Radiographs), содержащий рентгеновские снимки различных анатомических областей верхних конечностей. Несмотря на наличие исследований, посвящённых анализу данного датасета в целом, задачи автоматического выявления переломов плечевого сустава остаются менее изученными по сравнению с другими анатомическими зонами, такими как запястье или предплечье. Это обусловлено как сложностью анатомии плечевого сустава, так и высокой неоднородностью рентгенографических изображений, полученных в различных клинических условиях [1, 6].

В последние годы на мировом рынке медицинских технологий появились готовые коммерческие и исследовательские решения, предназначенные для автоматического анализа рентгенологических изображений. Среди них можно отметить системы компании Aidoc, Zebra Medical Vision, Qure.ai, а также исследовательские разработки крупных университетских центров. Эти системы ориентированы на выявление различных патологий костно-мышечной системы, включая переломы длинных костей, повреждения суставов и другие травматические изменения. Однако большинство существующих решений являются закрытыми коммерческими продуктами, не предоставляющими детальной информации об используемых архитектурах и алгоритмах, а также не ориентированными на специфические клинические условия отдельных регионов. Кроме того, специализированные модели для диагностики переломов именно плечевого сустава представлены в ограниченном количестве публикаций и требуют дальнейшего исследования и адаптации.

Актуальность настоящего исследования также обусловлена государственной политикой Республики Узбекистан в области цифровизации и внедрения технологий искусственного интеллекта в здравоохранение. В программных документах и стратегиях развития цифровой медицины особое внимание уделяется автоматизации диагностических процессов, внедрению интеллектуальных информационных систем и повышению качества медицинских услуг. Разработка интеллектуальных систем поддержки принятия врачебных решений рассматривается как важный шаг на пути модернизации медицинской отрасли и повышения доступности квалифицированной медицинской помощи.

В связи с этим целью данной работы является разработка и исследование интеллектуальной системы автоматического выявления переломов плечевого сустава на основе глубокой сверточной нейронной сети с использованием подвыборки XR_SHOULDER датасета MURA. В рамках исследования проводится обучение модели бинарной классификации («норма» / «перелом»), оценка её качества на валидационной

выборке и анализ полученных результатов с точки зрения применимости в клинической практике.

Методы. В данном исследовании использовались рентгенографические изображения плечевого сустава из открытого медицинского датасета MURA (Musculoskeletal Radiographs). Для обучения и оценки модели была выделена подвыборка XR_SHOULDER, содержащая изображения плечевого сустава с аннотациями «норма» и «перелом». Обучающая и валидационная выборки формировались на основе официальных CSV-файлов датасета MURA. Для устранения дисбаланса классов в обучающей выборке применялась балансировка.

Таблица 1 — Состав обучающей и валидационной выборок

Выборка	Норма	Перелом	Всего
Обучающая	4168	4168	8336
Валидационная	285	278	563

Рисунок 1 — Примеры рентгенографических изображений плечевого сустава из подвыборки



На рисунке 2 представлены примеры рентгенографических изображений плечевого сустава, используемых в качестве входных данных модели. Показаны изображения, относящиеся как к классу «норма», так и к классу «перелом». Снимки характеризуются различной ориентацией, контрастностью и степенью выраженности анатомических структур, что отражает реальные условия клинической рентгенографии. Наличие значительной вариативности входных данных обуславливает необходимость применения процедур предварительной обработки и аугментации при обучении нейронной сети.

Соотношение классов в обучающей выборке было приведено к значению 1:1 за счёт применения балансировки, что позволило обеспечить устойчивое обучение модели и корректную оценку её качества. Для приведения данных к единому виду применялась стандартная процедура предварительной обработки. Все изображения масштабировались до размера

224×224 пикселей и нормализовались по статистикам ImageNet. Для повышения обобщающей способности модели использовались аугментации данных, включающие случайные вращения до $\pm 15^\circ$, горизонтальные отражения, смещения до 10%, а также изменение яркости и контрастности. Данные операции моделируют вариативность условий получения рентгенографических снимков в клинической практике. В качестве базовой архитектуры использовалась сверточная нейронная сеть EfficientNet-B0, предварительно обученная на датасете ImageNet. Данная архитектура характеризуется эффективным использованием параметров и хорошим соотношением между точностью и вычислительной сложностью. Для решения задачи бинарной классификации стандартный выходной слой сети был адаптирован под два класса: «норма» и «перелом». Общее количество обучаемых параметров составило 4 664 446, все параметры участвовали в процессе обучения. Обучение модели проводилось в среде Google Colab с использованием графического процессора NVIDIA Tesla T4 (15.83 GB видеопамети). В качестве оптимизатора применялся алгоритм Adam с начальной скоростью обучения 0.0001 и размером батча 32 изображения. Использовался механизм динамического уменьшения скорости обучения ReduceLROnPlateau, а также метод ранней остановки при отсутствии улучшений на валидационной выборке в течение семи эпох.



Для оценки качества классификации применялись стандартные метрики бинарной классификации. Точность (Accuracy) определялась по формуле:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

где TP — число корректно классифицированных изображений с переломом, TN — число корректно классифицированных нормальных изображений, FP — число нормальных изображений, ошибочно отнесённых к классу «перелом», FN — число изображений с переломом, ошибочно классифицированных как норма.

Результат. Процесс обучения длился до 17 эпох, после чего был автоматически остановлен механизмом ранней остановки. На рисунке 1 представлена динамика изменения функции потерь на обучающей и валидационной выборках.

Рисунок 2 — Изменение функции потерь по эпохам и точности на обучающей и валидационной выборках



Из графика видно, что значение функции потерь на обучающей выборке монотонно уменьшается, в то время как значение функции потерь на валидационной выборке после 8–10 эпох начинает возрастать. Это свидетельствует о начале переобучения, что подтверждает корректность применения ранней остановки.

Максимальное значение точности на валидационной выборке было достигнуто на 10-й эпохе и составило 80.11%. После завершения обучения модель была протестирована на валидационной выборке. Итоговые показатели качества представлены в таблице 2.

Таблица 2 — Итоговые показатели качества классификации

Метрика	Значение
Accuracy	0.80
Precision	0.82
Recall	0.77
F1-score	0.80

Для более детального анализа результатов классификации была построена матрица ошибок, отражающая распределение корректных и ошибочных предсказаний модели для каждого класса. Матрица ошибок позволяет оценить характер допускаемых ошибок и соотношение между истинно положительными, истинно отрицательными и ошибочными классификациями.

Таблица 3 — Матрица ошибок модели для классификации изображений плечевого сустава

	Норма (предсказано)	Перелом (предсказано)
Норма	237	48
Перелом	64	214

Обсуждение. Полученные результаты показывают, что предложенная модель на основе архитектуры EfficientNet способна эффективно выявлять переломы плечевого сустава на рентгенографических изображениях. Достижение точности 80% на валидационной выборке подтверждает применимость подхода для задач автоматизированной диагностики. Основные ошибки модели связаны с пропуском слабо выраженных переломов и сложностью интерпретации рентгенограмм плечевого сустава, характеризующегося высокой анатомической вариативностью и наложением костных структур. Отсутствие механизма локализации области интереса приводит к тому, что модель принимает решение на основе всего изображения, что снижает чувствительность к мелким повреждениям.

Несмотря на это, баланс между точностью и полнотой классификации остаётся удовлетворительным, что подтверждается значением F1-меры, близким к 0.80.

Заключение. В данной работе разработана и исследована интеллектуальная система автоматического выявления переломов плечевого сустава на рентгенографических изображениях с использованием методов глубокого обучения. В качестве базовой архитектуры применена модель EfficientNet-B0, адаптированная под задачу бинарной классификации и обученная на подвыборке XR_SHOULDER датасета MURA. В ходе экспериментов была реализована полная процедура подготовки данных, включающая нормализацию изображений и аугментации, что позволило повысить устойчивость модели к вариациям рентгенографических снимков. Обучение проводилось с использованием оптимизатора Adam и механизма ранней остановки, предотвращающего переобучение. Полученные результаты показали, что модель

достигает точности классификации 80.11 % на валидационной выборке, демонстрируя сбалансированные значения основных метрик качества. Анализ матрицы ошибок показал, что наибольшие затруднения возникают при распознавании маловыраженных переломов, что объясняется отсутствием явных визуальных признаков и локализации области интереса. Разработанная система может использоваться как вспомогательный инструмент для первичной диагностики, способствующий снижению нагрузки на врача-рентгенолога и ускорению процесса анализа рентгенографических изображений. При этом модель не заменяет клиническое заключение специалиста, а предназначена для поддержки принятия решений.

В дальнейшем целесообразно расширить исследование за счёт внедрения методов сегментации и визуализации зон внимания нейронной сети, а также провести тестирование модели на клинических данных, что позволит повысить практическую ценность и надёжность предложенного подхода.

Литература

1. Chung S. W. et al. Automated detection and classification of the proximal humerus fracture by using deep learning algorithm. // *Acta orthopaedica*. Т. 89, №4, 2018. – С. 468-473.
2. Sperling Jr J. W. et al. A deep learning algorithm to detect proximal humerus fractures on radiographs. // *JSES Reviews, Reports and Techniques*, 2025.
3. Lundervold A.S., Lundervold A. An overview of deep learning in medical imaging focusing on MRI and X-ray. // *Zeitschrift für Medizinische Physik*. Vol. 29, №2, 2019. – P. 102-127.
4. Esteva A. et al. A guide to deep learning in healthcare. // *Nature medicine*. Т. 25, №1, 2019. – С. 24-29.
5. Tan M., Le Q. Efficientnet: Rethinking model scaling for convolutional neural networks. // *International conference on machine learning*. PMLR, 2019. – С. 6105-6114.
6. Zech J.R. et al. Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: a cross-sectional study. // *PLoS medicine*. Т. 15, №11, 2018. – С. e1002683.