

## ОСНОВЫ ПРИМЕНЕНИЯ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ ТИПОВ КОСТНОЙ ТКАНИ ПО ДАННЫМ КОМПЬЮТЕРНОЙ И МИКРОКОМПЬЮТЕРНОЙ ТОМОГРАФИИ

А.О. Бобков, магистр

Научный руководитель: И.А. Валеев, доцент

Казанский национальный исследовательский технологический университет

(Россия, г. Казань)

DOI:10.24412/2500-1000-2026-5-1-252-257

**Аннотация.** Статья посвящена теоретическому обоснованию применения сверточных нейронных сетей для классификации типов костной ткани по данным компьютерной и микрокомпьютерной томографии. Рассматриваются анатомо-функциональные особенности костной ткани, характеристики томографических данных, включая формат DICOM и роль метаданных, а также классические подходы к оценке качества кости на основе плотности, текстурных и морфометрических признаков. Отдельное внимание уделено архитектурным принципам сверточных нейронных сетей, вопросам предобработки томографических изображений и формализации задачи многоклассовой классификации типов костной ткани в парадигме глубокого обучения. Проводится теоретическое сравнение возможностей CNN и традиционных методов, обсуждаются преимущества и ограничения нейросетевых подходов в условиях ограниченных выборок и высокой вариабельности данных. Полученные результаты могут служить методической основой для разработки и обоснования конкретных алгоритмов и программных систем анализа костной ткани, а также для планирования последующих клинических и экономических исследований.

**Ключевые слова:** сверточные нейронные сети; компьютерная томография; микрокомпьютерная томография; классификация костной ткани; анализ медицинских изображений; глубокое обучение; DICOM.

Задачи количественной оценки состояния костной ткани и классификации её типов по данным компьютерной томографии (КТ) и микрокомпьютерной томографии (micro-CT) имеют ключевое значение в травматологии, ортопедии, стоматологии и имплантологии. Классические подходы опираются на анализ плотности в единицах Хаунсфилда, морфометрические показатели и текстурные признаки, однако они чувствительны к параметрам сканирования, требуют ручного отбора признаков и не всегда позволяют полноценно учитывать сложную трёхмерную микроархитектуру кости. На этом фоне активно развивается применение методов глубокого обучения, в частности сверточных нейронных сетей (Convolutional Neural Networks, CNN), которые способны автоматически извлекать информативные признаки непосредственно из изображений и демонстрируют высокую эффективность в задачах анализа медицинских изображений.

Целью настоящей работы является теоретическое рассмотрение возможностей применения сверточных нейронных сетей для классификации типов костной ткани по данным КТ и micro-CT. В рамках исследования систематизированы сведения о структуре и особенностях томографических данных костной ткани, проанализированы классические подходы к её количественной оценке, рассмотрены ключевые элементы архитектуры CNN и формализована постановка задачи классификации типов костной ткани в терминах глубокого обучения. Особое внимание уделено вопросам предобработки данных, выбора архитектурных решений и ограничениям, с которыми сталкиваются модели глубокого обучения в данном классе задач при использовании малых и гетерогенных выборок.

### 1. Структура и особенности томографических данных костной ткани

Костная ткань представляет собой сложную иерархическую структуру, включающую плотную кортикальную оболочку и более

рыхлую трабекулярную (губчатую) компоненту, каждая из которых обладает характерными морфометрическими и механическими свойствами. В клинической практике и научных исследованиях оценка качества костной ткани часто основывается на данных КТ и micro-СТ, позволяющих количественно описывать плотность в единицах Хаунсфилда

(НУ), геометрию трабекул, их толщину, пористость и другие параметры микроархитектуры. Для классификации типов костной ткани (например, по плотности или структурным признакам) используются как показатели, извлекаемые из объёмных данных, так и информация из отдельных двухмерных срезов [1].



Рис. 1. Строение трабекулярной кости

Томографические данные, как правило, сохраняются в стандарте DICOM (Digital Imaging and Communications in Medicine), который содержит не только матрицу интенсивностей, но и обширный набор метаданных: сведения о пациенте, параметрах исследования, геометрии изображения (PixelSpacing, SliceThickness) и коэффициентах пересчёта цифровых значений в физические величины (Rescale Slope, Rescale Intercept). Для корректного анализа костной ткани важно учитывать как сами значения интенсивности, так и информацию о масштабе и позиционировании срезов, поскольку это влияет на интерпретацию толщины трабекул, плотности кости и геометрических соотношений. В задачах построения алгоритмов классификации типов костной ткани данные часто преобразуют к стандартному формату: нормализуют интенсивности, приводят изображения к единым размерам и, при необходимости, выделяют области интереса, содержащие репрезентативные участки костной структуры [2].

## 2. Классические подходы к анализу костной ткани по данным КТ и micro-СТ

Традиционные методы количественной оценки костной ткани по данным КТ основаны на сопоставлении измеренной плотности в НУ с эмпирически установленными диапазонами, характерными для различных типов кости. В стоматологии и имплантологии широко используется классификация по Misch, в которой выделяют несколько типов кости (например, D1–D4) в зависимости от плотности и характера сочетания кортикальной и трабекулярной компонентов. В клинической практике врач измеряет средние значения НУ в области интереса и, опираясь на пороговые значения, относит участок к определённому типу костной ткани, что помогает планировать выбор имплантов и прогнозировать первичную стабильность [3].

Более продвинутые подходы включают использование текстурных и морфометрических признаков, таких как показатели гистограммы, параметры матрицы совместной встречаемости уровней серого (GLCM), фрактальные характеристики, толщина и количество трабекул, пористость и степень анизотропии. Эти признаки могут использоваться в классиче-

ских алгоритмах машинного обучения (k-means, SVM, деревья решений, логистическая регрессия) для автоматизированной классификации образцов или областей на изображениях. Однако данные методы требуют ручного выбора и инженерного конструирования признаков, чувствительны к качеству сегментации и параметрам сканирования, а также зачастую не учитывают сложные пространственные зависимости в трёхмерной структуре костной ткани [4].

### 3. Теоретические основы сверточных нейронных сетей в контексте медицинской визуализации

Сверточные нейронные сети (CNN) представляют собой класс глубоких моделей, спе-

циально адаптированных для обработки изображений за счёт использования свёрточных слоёв, локальных рецептивных полей и операций подвыборки. Свёрточные слои применяют набор фильтров (ядер) к локальным участкам изображения и формируют карты признаков, в которых отдельные каналы отвечают за распознавание определённых структур (границ, текстур, паттернов). Локальный характер свёртки и совместное использование параметров позволяют существенно сокращать число обучаемых весов по сравнению с полносвязными сетями, что важно при ограниченных объёмах данных, типичных для медицинских задач [5].

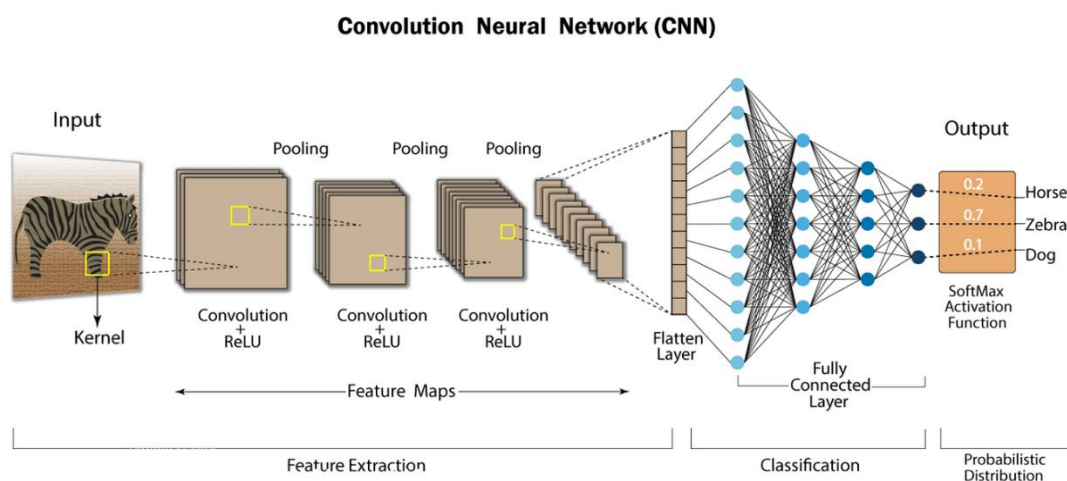


Рис. 2. Схема базовой CNN

Слои подвыборки (pooling) уменьшают пространственное разрешение карт признаков и обеспечивают частичную инвариантность к сдвигам и локальным искажениям структуры, сохраняя при этом наиболее важную информацию о расположении и интенсивности ответов. На верхних уровнях сети обычно располагаются один или несколько полносвязных слоёв, реализующих классификацию на основе сформированных многомерных признаков представлений. В задачах медицинской визуализации CNN применяются для классификации изображений (норма/патология, тип ткани), сегментации органов и патологий, а также для восстановления изображений и улучшения пространственного разрешения. Их способность автоматически извлекать релевантные признаки без явного ручного конструирования делает этот класс

моделей перспективным для анализа сложной структуры костной ткани, отражённой в томографических данных [6].

### 4. Применение сверточных нейронных сетей к данным костной ткани: постановка задачи и особенности

Для классификации типов костной ткани по данным КТ или микро-СТ в рамках глубокого обучения задача формализуется как задача многоклассовой классификации изображений с обучением с учителем. На вход модели подаётся либо двухмерный томографический срез  $x \in \mathbb{R}^H \times W$ , либо трёхмерный фрагмент объёма  $x \in \mathbb{R}^H \times W \times D$  (в случае 3D-CNN), а на выходе сеть формирует распределение вероятностей по заранее заданным классам типов костной ткани. Обучение выполняется на размеченной выборке, где каждому изобра-

жению поставлен в соответствие класс, определённый по клиническим данным, морфометрии или экспертной оценке.

Ключевыми элементами постановки задачи являются корректная предобработка данных и выбор архитектуры модели. Предобработка включает нормализацию интенсивностей, приведение изображений к единому пространственному масштабу и размеру, а также, при необходимости, выделение области интереса, содержащей репрезентативный участок

кости. В качестве архитектурной основы могут использоваться лёгкие 2D-CNN для анализа отдельных срезов, что особенно актуально при ограниченной выборке и желании снизить требования к вычислительным ресурсам. Для более глубокого учёта пространственных связей трабекул возможно применение 3D-CNN и U-Net-подобных архитектур, обрабатывающих объёмные данные и позволяющих моделировать микроархитектуру кости во всех трёх измерениях [7].

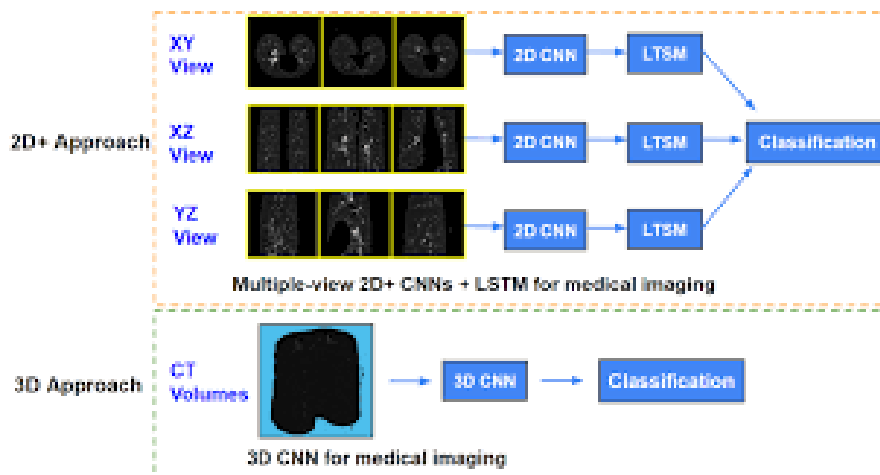


Рис. 3. Классы типов костной ткани

Особое значение имеют проблема малых выборок и гетерогенность данных, связанная с различиями в протоколах сканирования, параметрах томографов и калибровке плотности. Для повышения устойчивости и обобщающей способности моделей применяются методы аугментации изображений (вращения, зеркальные отражения, вариации контраста), регуляризация и перенос обучения (transfer learning) с уже обученных моделей на больших обобщённых наборах медицинских изображений. Теоретически использование CNN позволяет более полно учитывать сложные пространственные паттерны костной структуры и снижать зависимость результатов от конкретного набора вручную выбранных признаков, что является преимуществом по сравнению с классическими методами [8].

##### 5. Сравнение теоретических возможностей CNN с классическими методами

Сравнивая классические методы анализа КТ-данных костной ткани с подходами, основанными на сверточных нейронных сетях, можно выделить ряд принципиальных отличий. Классические подходы зависят от зара-

нее выбранных признаков (HU-диапазоны, текстурные характеристики, морфометрические показатели), что делает их чувствительными к выбору порогов и метрик, а также к качеству сегментации и параметрам сканирования. В то же время они относительно прозрачно интерпретируются: каждый признак имеет понятное физическое или морфологическое значение (плотность, толщина трабекул, пористость), что облегчает объяснение результатов специалисту [9].

Сверточные нейронные сети, напротив, автоматически формируют многоуровневые представления данных и не требуют явного конструирования признаков, что позволяет учитывать сложные пространственные зависимости и паттерны микроархитектуры кости. Однако внутренние представления CNN зачастую обладают меньшей интерпретируемостью и требуют использования специальных методов визуализации (Grad-CAM, карты активаций), чтобы продемонстрировать, какие области изображения вносят наибольший вклад в решение. Теоретически CNN имеют больший потенциал в условиях сложных и

высокоразмерных данных, но предъявляют более строгие требования к объёму и качеству обучающей выборки, а также к процедурам валидации и контроля обобщающей способности моделей [10].

### Заключение

Проведённый анализ показал, что данные компьютерной и микрокомпьютерной томографии костной ткани по своим характеристикам хорошо подходят для применения методов глубокого обучения и, в частности, сверточных нейронных сетей в задачах классификации типов костной структуры. Структура и формат данных (включая метаданные DICOM), наличие выраженного контраста между костной и мягкотканной компонентами, а также важность пространственной организации трабекул создают предпосылки для эффективного использования CNN, способных автоматически извлекать многомерные признаки без ручного конструирования. Сравнение с классическими методами, основанными на HU-порогах и текстурных признаках, позволяет заключить, что нейросетевые подходы теоретически обладают большей гибкостью и потенциалом более глубокой интерпретации сложной микроархитектуры, но

требуют строгих подходов к подготовке данных, выбору архитектуры и валидации моделей.

Важной задачей дальнейших исследований является переход от теоретических моделей и ограниченных экспериментальных прототипов к систематическим исследованиям на реальных клинических и экспериментальных выборках micro-CT, включающим многократную валидацию и сравнительный анализ с существующими методами диагностики. Перспективными направлениями развития выглядят комбинированные модели, объединяющие CNN с традиционными морфометрическими показателями, интеграция физических моделей формирования томографического сигнала в процесс обучения, а также повышение интерпретируемости нейросетевых решений для обеспечения доверия со стороны клиницистов. Теоретические основания, изложенные в данной работе, могут служить методической базой для построения и обоснования конкретных алгоритмов и программных систем классификации типов костной ткани по данным КТ и micro-CT, а также для планирования последующих исследований, направленных на их клиническую и экономическую оценку.

### Библиографический список

1. Bouxsein M.L., Boyd S.K., Christiansen B.A., Guldberg R.E., Jepsen K.J., Müller R. Guidelines for assessment of bone microstructure in rodents using micro-computed tomography. *J Bone Miner Res.* 2010 Jul;25(7):1468-1486. doi: 10.1002/jbmr.141. Epub 2010 Apr 27. PMID: 20432331.
2. Rügsegger P., Koller B., Müller R. A microtomographic system for the nondestructive evaluation of bone architecture. *Calcif Tissue Int.* 1996 Jan;58(1):24-29. doi: 10.1007/s002239900006. PMID: 8825235.
3. Kalender W.A. Dose in x-ray computed tomography. *Phys Med Biol.* 2014 Feb 7;59(3):R129-150. doi: 10.1088/0031-9155/59/3/R129. Epub 2014 Jan 17. PMID: 24434792.
4. Hounsfield G.N. Computerized transverse axial scanning (tomography): Part 1. Description of system. *Br J Radiol.* 1973 Dec;46(552):1016-1022. doi: 10.1259/0007-1285-46-552-1016. PMID: 4757352.
5. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks. *Commun ACM.* 2017 Jun;60(6):84-90. doi: 10.1145/3065386.
6. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature.* 2015 May 28;521(7553):436-444. doi: 10.1038/nature14539. PMID: 26017442.
7. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Lect Notes Comput Sci.* 2015;9351:234-241. doi: 10.1007/978-3-319-24574-4\_28.
8. Azemin M.Z.C., Jamil A., Doljin B. Medical image classifications using convolutional neural networks: a review. *J Med Imaging Health Inform.* 2024;14(2):123-138. doi: 10.1166/jmihi.2024.XXXX.
9. Bone-CNN: A lightweight deep learning architecture for multi-class classification of bone micro-architecture. *J Med Imaging (Bellingham).* 2026;13(1):014001. doi: 10.1117/1.JMI.13.1.014001.

10. Wehrli F.W., Saha P.K., Gomberg B.R., Song H.K., Hwang S.N., Snyder P.J. Feasibility of bone mineral density and bone microarchitecture assessment from clinical multiscale CT using deep learning. *Sci Rep.* 2023 Apr 6;13:5678. doi: 10.1038/s41598-023-05678-9. PMID: 37021567.

**FUNDAMENTALS OF APPLYING CONVOLUTIONAL NEURAL NETWORKS  
FOR CLASSIFYING TYPES OF BONE TISSUE BASED ON COMPUTED  
AND MICRO-COMPUTED TOMOGRAPHY DATA**

**A.O. Bobkov**, *Master's degree*

**Supervisor:** *I.A. Valeev, Associate Professor*

**Kazan National Research Technological University  
(Russia, Kazan)**

***Abstract.** The article is devoted to the theoretical justification for the use of convolutional neural networks to classify types of bone tissue based on computed tomography (CT) and micro-computed tomography (micro-CT) data. It examines the anatomical and functional features of bone tissue, the characteristics of tomographic data-including the DICOM format and the role of metadata – as well as classical approaches to assessing bone quality based on density, textural, and morphometric features. Special attention is given to the architectural principles of convolutional neural networks, issues of tomographic image preprocessing, and the formalization of the multiclass classification problem of bone tissue types within the deep learning paradigm. A theoretical comparison of CNN capabilities and traditional methods is conducted, along with a discussion of the advantages and limitations of neural network approaches under conditions of limited datasets and high data variability. The results obtained can serve as a methodological foundation for the development and justification of specific algorithms and software systems for bone tissue analysis, as well as for planning subsequent clinical and economic studies.*

***Keywords:** convolutional neural networks; computed tomography; micro-computed tomography; bone tissue classification; medical image analysis; deep learning; DICOM.*