

doi: 10.17586/2226-1494-2026-26-1-77-84

УДК 004.89

## Выбор полиномиальных функций в сетях Колмогорова–Арнольда для сегментации медицинских изображений в условиях малых выборок

Геннадий Юрьевич Манжос<sup>1</sup>, Иван Вячеславович Томилов<sup>2</sup>,  
Нагалия Федоровна Гусарова<sup>3</sup>, Юлия Олеговна Валитова<sup>4</sup>

<sup>1</sup> Приволжский исследовательский медицинский университет, Нижний Новгород, 603005, Российская Федерация

<sup>1,2,3,4</sup> Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

<sup>1</sup> [manzhos\\_gy@pimunn.net](mailto:manzhos_gy@pimunn.net), <https://orcid.org/0009-0007-8551-1908>

<sup>2</sup> [ivan-tomilov3@yandex.ru](mailto:ivan-tomilov3@yandex.ru), <https://orcid.org/0000-0003-1886-2867>

<sup>3</sup> [nfgusarova@itmo.ru](mailto:nfgusarova@itmo.ru), <https://orcid.org/0000-0002-1361-6037>

<sup>4</sup> [yulia.o.valitova@itmo.ru](mailto:yulia.o.valitova@itmo.ru), <https://orcid.org/0000-0001-5345-5461>

### Аннотация

**Введение.** Современные методы обработки медицинских изображений в большей части основаны на сверточных нейронных сетях и архитектурах трансформер. Главной проблемой является значительный объем параметров существующих моделей нейронных сетей, что ведет к высоким требованиям к вычислительным ресурсам диагностических медицинских систем. **Метод.** Сети Колмогорова–Арнольда, построенные на основе сплайн-функций, демонстрируют сопоставимую точность с традиционными архитектурами, при этом имеют значительно меньшее число параметров. В сверточных слоях сети Колмогорова–Арнольда возможно использование различных базисных полиномиальных функций вместо сплайнов, что существенно влияет на качество сегментации. В работе представлено сравнение эффективности 22 различных полиномиальных функций в сети Колмогорова–Арнольда при сегментации двухмерных медицинских изображений на малых выборках. **Основные результаты.** Экспериментальные данные показали, что исследуемые полиномиальные функции достигают производительности, сопоставимой с передовыми моделями трансформер при значительно меньшем количестве параметров. **Обсуждение.** Полученные результаты подтверждают перспективность дальнейшего изучения полиномиальных функций в архитектуре сверточных блоков сетей Колмогорова–Арнольда, особенно при ограниченных вычислительных ресурсах. Необходимы дальнейшие исследования полиномиальных функций в сверточных слоях сети Колмогорова–Арнольда в задачах обработки высокотехнологичных медицинских изображений.

### Ключевые слова

медицинская сегментация, полиномиальные функции, глубокое обучение, KAN-UNet, сети Колмогорова–Арнольда

### Благодарности

Исследование поддержано грантом Российского научного фонда № 23-11-00346.

**Ссылка для цитирования:** Манжос Г.Ю., Томилов И.В., Гусарова Н.Ф., Валитова Ю.О. Выбор полиномиальных функций в сетях Колмогорова–Арнольда для сегментации медицинских изображений в условиях малых выборок // Научно-технический вестник информационных технологий, механики и оптики. 2026. Т. 26, № 1. С. 77–84. doi: 10.17586/2226-1494-2026-26-1-77-84

## Polynomial function selection in Kolmogorov-Arnold Networks for medical image segmentation with limited data

Gennadiy Yu. Manzhos<sup>1</sup>✉, Ivan V. Tomilov<sup>2</sup>, Natalia F. Gusarova<sup>3</sup>, Yulia O. Valitova<sup>4</sup>

<sup>1</sup> Privolzhsky Research Medical University, Nizhniy Novgorod, 603005, Russian Federation

<sup>1,2,3,4</sup> ITMO University, Saint Petersburg, 197101, Russian Federation

<sup>1</sup> manzhos\_gy@pimunn.net✉, <https://orcid.org/0009-0007-8551-1908>

<sup>2</sup> ivan-tomilov3@yandex.ru, <https://orcid.org/0000-0003-1886-2867>

<sup>3</sup> nfgusarova@itmo.ru, <https://orcid.org/0000-0002-1361-6037>

<sup>4</sup> yulia.o.valitova@itmo.ru, <https://orcid.org/0000-0001-5345-5461>

### Abstract

Modern methods for processing medical images are mostly based on convolutional neural networks and transformer architectures. A major issue is the large number of parameters in existing neural network models, which leads to high computational resource requirements. Kolmogorov-Arnold Networks, built upon spline functions, demonstrate comparable accuracy to traditional architectures while having significantly fewer parameters. In the convolutional layers of Kolmogorov-Arnold Networks, various polynomial basis functions can be used instead of splines, which substantially affect segmentation quality. The objective of this study is to compare the effectiveness of 22 different polynomial functions within Kolmogorov-Arnold Networks for segmenting two-dimensional medical images on small datasets. Experimental results show that the polynomial functions studied achieve performance comparable to state-of-the-art transformer models while requiring significantly fewer parameters. The obtained results confirm the promising potential of further research into polynomial functions within the convolutional blocks of Kolmogorov-Arnold Networks, especially under limited computational resources. Further studies of polynomial functions in the convolutional layers of Kolmogorov-Arnold Networks are necessary for processing advanced medical imaging data.

### Keywords

medical segmentation, polynomial functions, deep learning, KAN-UNet, Kolmogorov-Arnold Networks

### Acknowledgements

This research was supported by the Russian Science Foundation No. 23-11-00346.

**For citation:** Manzhos G.Yu., Tomilov I.V., Gusarova N.F., Valitova Yu.O. Polynomial function selection in Kolmogorov-Arnold Networks for medical image segmentation with limited data. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2026, vol. 26, no. 1, pp. 77–84 (in Russian). doi: 10.17586/2226-1494-2026-26-1-77-84

### Введение

Под медицинским изображением понимается визуальная репрезентация структуры и функций различных тканей и органов человеческого тела для клинических целей [1–3]. В последние годы внимание исследователей привлекают высокотехнологичные медицинские изображения (ВТМИ) [4–7], для формирования которых используют специализированные ресурсоемкие технологии, такие как компьютерная (КТ), магнитно-резонансная (МРТ) и позитронно-эмиссионная томографии, цифровая маммография и другие. Получение и автоматизированная обработка ВТМИ является составной частью оказания высокотехнологичной медицинской помощи во многих странах, в том числе в Российской Федерации.

Несмотря на физически различное происхождение перечисленных изображений, они имеют ряд объединяющих признаков: алгоритмическая и вычислительная сложности обработки; многомерность (трехмерные томографические срезы, пространственно-временные последовательности, мультиспектральные данные); типизация решаемых задач (классификация и/или сегментация); высокие требования к точности и объяснимости результата. Это позволяет рассматривать задачи обработки ВТМИ с единых алгоритмических позиций и в то же время заставляет использовать в качестве технологической базы наиболее продвинутые архитектурные решения.

До последнего времени в глубоком обучении доминировали архитектуры на основе сверточных нейрон-

ных сетей [8–11] и трансформеров [12–14]. Однако их эффективность критически зависит от наличия значительных вычислительных ресурсов и больших наборов данных. Для многих задач практической медицины, таких как диагностика редких и сочетанных заболеваний, эти ограничения часто являются непреодолимыми. В качестве альтернативы может быть рассмотрена архитектура сети Колмогорова–Арнольда (Kolmogorov-Arnold Network, KAN) [15], в которой функция преобразования  $f(x)$  входного вектора  $x$  строится на базе теоремы Колмогорова–Арнольда [16]:

$$f(x) = f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} \Phi_q \left( \sum_{p=1}^n \Psi_{q,p}(x_p) \right), \quad (1)$$

где  $n$  — число переменных исходной функции  $f$ ;  $q$  — индекс функции, соответствующий внешнему суммированию;  $p$  — индекс суммирования;  $\Phi_q$  — непрерывная обучаемая функция, применяемая к сумме значений;  $\Psi_{q,p}$  — обучаемая функция одной переменной;  $x_p$  —  $p$ -й элемент входного вектора  $x$ . Вместо обучения весов нейронов, как в традиционных нейронных сетях, в KAN обучению подлежат функции активации  $\psi$  — одномерные функции сплайнового (полиномиального) типа с небольшим числом варьируемых параметров, что принципиально снижает требования к вычислительным ресурсам и объему обучающих данных.

Возможность использования KAN для обработки ВТМИ уже подтверждена в работах [17–19]. Однако, как видно из выражения (1), эффективность KAN критически зависит от удачного выбора типа функций  $\psi$  для конкретного вектора  $x$  и доступного объема обуча-

ющей выборки. При обработке сложных входных объектов, в частности, для сегментации ВТМИ, такой выбор представляет самостоятельную проблему, которая только начинает рассматриваться в [20], в то время как существующая работа [21] сосредоточена на больших объемах выборок и не учитывает специфику ВТМИ.

В настоящей работе экспериментально изучается зависимость эффективности KAN от выбора типа обучаемых функций активации при обработке различных типов ВТМИ в условиях малых обучающих выборок. Задачи исследования формулируются следующим образом: выявить, какие полиномиальные функции демонстрируют наилучшие результаты при сегментации ВТМИ в условиях малых обучающих выборок; провести сравнение эффективности архитектур KAN и наилучших существующих моделей (State of the Art, SOTA) в задаче сегментации ВТМИ на бенчмаркингных наборах данных в условиях малых обучающих выборок.

## Материалы и методы

**Архитектура.** В работе использована сеть KANU-Net 2D [22], которая основана на сети U-Net [23], но заменяет стандартные сверточные слои Conv2D на Fast KAN Convolutional Layers (FastKANConvLayers). Каждый слой FastKANConvLayer включает преобразование входных признаков с использованием одной из базисных полиномиальных функций (БПФ): Radial Basis Function (RBF), B-spline, полиномы Чебышёва (Chebyshev) и полиномы Фурье (Fourier). Сеть включает в себя энкодер — серию блоков DoubleConv (два последовательных FastKANConvLayers, за которыми следует пакетная нормализация и активация Rectified Linear Unit и декодер. Сеть обрабатывает 2D-изображения, имея на входе количество каналов равное размерности входным данным набора данных. Все изображения стандартизированы до размера 128×128 пикселей и обрабатываются батчами по два изображения. На выходе сети ожидается маска сегментации с тем же размером, где каждому пикселу сопоставлена вероятность принадлежности к конкретному классу.

В настоящей работе использован расширенный набор БПФ: RBF, Chebyshev, Fourier, B-spline, Al-Salam-Carlitz, Bannai-Ito, Askey-Wilson, Boas-Buck, Boubaker, Charlier, Fermat, Gottlieb, Heptanacci, Hexanacci, Meixner-Pollaczek, Narayana, Octanacci, Pado, Pentanacci, Tetranacci, Tribonacci, Vieta-Pell [24].

**Наборы данных и предобработка.** Для исследований выбраны характерные типы ВТМИ: МРТ изображения мозга, КТ изображения легких, ультразвуковые изображения легких и видеозаписи колоноскопии. Для проведения экспериментов в настоящей работе использованы свободно распространяемые бенчмарковые наборы ВТМИ: BraTS 2020 [25], LIDC-IDRI [26], BUSI [27] и CVC-ClinicDB [28]. Для обеспечения режима малых выборок из каждого набора данных случайным образом извлекались три обучающие подвыборки (тренировочная, валидационная и тестовая) объемом 50 сэмплов в каждой. В наборах данных LIDC-IDRI и BUSI используется один канал, представляющий интенсивность сигнала в каждой точке изображения; в

BraTS 2020 — три канала: все опухолевые ткани, ядро опухоли и контраст-накапливающая часть опухоли; в CVC-ClinicDB — три канала, соответствующие красному, зеленому и синему цветам.

Все изображения были приведены к единому размеру 128 × 128 пикселей; каждое изображение было нормализовано в диапазоне [−1, 1] с использованием масштабирования min-max, а значения выходных масок нормализованы в диапазоне [0, 1], где 0 означает отсутствие искомого объекта, а 1 — его наличие в данной точке изображения.

**Обучение сети.** В качестве функции потерь использована комбинированная функция потерь (Combined loss), которая объединяет Dice loss и Binary Cross Entropy (BCE). Такой подход обеспечивает оптимизацию качества семантической сегментации как по показателю перекрытия сегментированных областей, так и по точности классификации на уровне отдельных пикселей [29].

Функция потерь Dice loss минимизируется, когда сегментация сети совпадает с маской, и равна

$$Dice\ loss = 1 - \frac{2\sum_i p_i g_i}{\sum_i p_i + \sum_i g_i},$$

где  $p_i$  — предсказанное значение для пикселя  $i$ ;  $g_i$  — истинная метка (0 или 1).

Функция потерь BCE применяется для оценки ошибки бинарной классификации каждого пикселя, измеряя насколько точно модель предсказывает принадлежность каждого пикселя к классу метки или фона:

$$BCE = -\frac{1}{N} \sum_{i=1}^N y_i \ln(p_i) + (1 - y_i) \ln(1 - p_i),$$

где  $N$  — количество пикселей в изображении;  $y_i$  — истинная метка (0 или 1) пикселя  $i$ ;  $p_i$  — предсказанная моделью вероятность принадлежности пикселя  $i$  к классу 1.

Таким образом, комбинированная функция потерь рассчитывается как

$$Combined\ loss = (\alpha \times BCE + (1 - \alpha) \times Dice\ loss).$$

Значение  $\alpha = 0,2$  подобрано эмпирически для обеспечения стабильности обучения и оптимального качества итоговой сегментации. Для оптимизации использован оптимизатор AdamW — обучение проводится с применением метода градиентного спуска с начальной скоростью обучения равной 0,0001 и регуляризацией — 0,00001. Для динамической корректировки скорости обучения во время тренировки использовался планировщик косинусного отжига, с периодом 100, множителем периода 1 и минимальной скоростью обучения 0,001. Эксперименты проводились с применением следующей конфигурации: размер батча 2; четыре узловых точки в сети KAN; [−3,0, 3,0] диапазон точек сети KAN; 400 эпох для наборов данных CVC-ClinicDB, BUSI, LIDC-IDRI и 100 эпох для BraTS 2020; фреймворки PyTorch, MONAI, OpenCV и Transformers.

**Метрики оценки качества сегментации.** В работе проведена комплексная оценка эффективности оцениваемых сетей, включающая основные метрики сегментации:

$$IoU = \frac{TP}{(TP + FP + FN)}, \quad (2)$$

$$Dice = \frac{2|X \cap Y|}{|X| + |Y|}, \quad (3)$$

где TP, TN, FP, FN — истинно положительные, истинно отрицательные, ложно положительные и ложноотрицательные метки класса соответственно;  $X$  — предсказанная область;  $Y$  — маска сегментации; IoU — пересечение над объединением (Intersection over Union, IoU).

Методика эксперимента состояла из следующих шагов:

- обучение сети KANU-Net 2D с использованием 22 различных БПФ на подвыборках из 50 изображений на четырех бенчмарковых медицинских наборах данных;

- сравнение результатов их качества работы по метрикам эффективности (2) и (3) и выявление группы наиболее удачных БПФ для задач медицинской сегментации.

### Результаты и обсуждение

Сравнение результатов сегментации, проведенное врачами-экспертами на качественном уровне (визуально), показало, что для всех отобранных типов ВТМИ задача сегментации решена удовлетворительно. Примеры предъявленных экспертам изображений представлены в табл. 1.

Количественные значения метрик сегментации (2) и (3), выполненной сетью KANU-Net 2D при использовании различных БПФ, представлены в табл. 2. Для каждого набора данных получены наилучшие результаты<sup>1</sup> для трех БПФ; полужирным шрифтом отмечены максимальные значения метрик Dice и IoU.

<sup>1</sup> Полные результаты могут быть предоставлены по запросу.

Таблица 1. Визуальное представление сегментации медицинских изображений с базисными полиномиальными функциями в тестовых наборах данных

Table 1. Visualization of medical image segmentation with different polynomial functions on test datasets

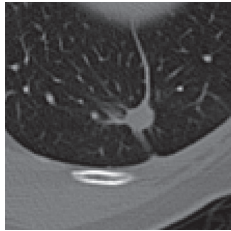


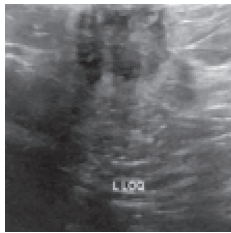


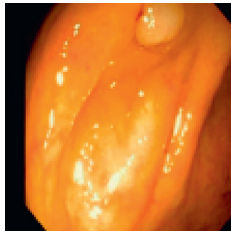


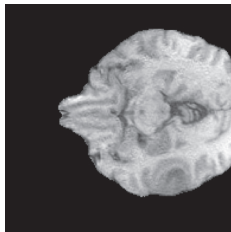
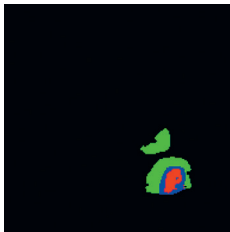

Базисные полиномиальные функции	Оригинал	Маска эксперта	Предсказанная маска	Тестовый набор данных
Tribo				LIDC-IDRI
Tribo				BUSI
Bannai-Ito				CVC-ClinicDB
Al-Salam-Carlitz				BraTS 2020

Таблица 2. Сравнение эффективности БПФ на четырех наборах данных  
 Table 2. Comparison of the efficacy of polynomial functions across four datasets

БПФ	Dice, %	IoU, %
Набор данных LIDC-IDRI		
<b>Tribo</b>	<b>77,6</b>	<b>63,4</b>
Hexanacci	77,2	62,8
Octanacci	77,0	62,6
Набор данных CVC-ClinicDB		
<b>Bannai-Ito</b>	<b>81,3</b>	<b>68,6</b>
Gottlieb	80,1	66,9
Boas-Buck	79,8	66,7
Набор данных BUSI		
<b>Tribo</b>	<b>59,6</b>	<b>42,9</b>
Bannai-Ito	57,5	40,4
Boubaker	57,2	40,1
Набор данных BraTS 2020		
<b>Al-Salam-Carlitz</b>	<b>82,2</b>	<b>79,2</b>
Boubaker	80,7	77,3
Charlier	80,7	78,9

В табл. 3 приведено сравнение эффективности наилучших БПФ (табл. 2), с найденными SOTA-моделями. Для повышения объективности сравнения, наряду со значениями метрик (2) и (3), для каждой модели приводятся размеры обучающей выборки и анализируемого изображения. В SOTA-модели КТ легких [30] обучение проводилось на наборе данных PRD<sup>1</sup>, идентичном по

<sup>1</sup> The Pelvic-Reference-Data. The Cancer Imaging Archive (TCIA) [Электронный ресурс]. Режим доступа: <https://www.cancerimagingarchive.net/collection/pelvic-reference-data/> (дата обращения: 17.05.2025).

тематике и параметрам разрешения с набором данных LIDC-IDRI. Во всех остальных SOTA-моделях применены те же обучающие наборы данных, что и в настоящей работе.

Результаты табл. 3 показывают, что эффективность сегментации ВТМИ, выполненной сетью KANU-Net 2D при использовании лучших БПФ, сопоставима, а в некоторых случаях (при сегментации трехмерных изображений МРТ мозга) превосходит результаты SOTA-моделей, полученные при обучении на значительно больших тренировочных данных.

Таблица 3. Сравнение эффективности наилучших БПФ с SOTA-моделями  
 Table 3. Comparison of the efficacy of polynomial functions with SOTA-models

Тематика	Методика эксперимента	Набор данных	Выборка, шт.	Размер изображения	Dice, %	IoU, %
SOTA-модели						
КТ легких	[30]	PRD	188	512 × 512 мм <sup>2</sup>	86,5	—
Колоноскопия	[31]	CVC-ClinicDB	612	256 × 256 мм <sup>2</sup>	94,1	88,9
УЗИ молочной железы	[31]	BUSI	647	256 × 256 мм <sup>2</sup>	77,6	63,4
МРТ мозга	[32]	BraTS-GLI 2024	1350	182 × 182 × 218 мм <sup>3</sup>	74,5	66,2
Лучшие БПФ в настоящей работе						
КТ легких	—	LIDC-IDRI	50	128 × 128 мм <sup>2</sup>	77,6	63,4
Колоноскопия	—	CVC-ClinicDB	50	128 × 128 мм <sup>2</sup>	81,3	68,6
УЗИ молочной железы	—	BUSI	50	128 × 128 мм <sup>2</sup>	59,6	42,9
МРТ мозга	—	BraTS 2020	50	128 × 128 × 155 мм <sup>3</sup>	82,2	79,2

## Заклучение

Рассмотрены основные методы сегментации в медицинских изображениях на примере бенчмарковых наборов данных LIDC-IDRI, BUSI, CVC-ClinicDB, BraTS 2020. Выполнено сравнение основных методов сегментации с использованием сверточных нейронных сетей Колмогорова–Арнольда и архитектур на базе трансформеров. Показано, что выбор различных базисных полиномиальных функций внутри сверточных блоков сети существенно влияет на точность медицинской сегментации. Выполненные эксперименты демон-

стрируют перспективность дальнейшего исследования применения базисных полиномиальных функций в архитектуре сверточных блоков сети KANU-Net 2D. Наибольший интерес вызывают функции Tribo, Al-Salam-Carlitz, Gottlieb, Bannai-Ito, Hexanacci, Octanacci, так как они показали высокие результаты коэффициента Dice на всех четырех исследуемых наборах данных. Необходимы дальнейшие исследования полиномиальных функций для их применения в сверточных слоях сети Колмогорова–Арнольда в задачах обработки высокотехнологичных медицинских изображений.

## Литература

1. Cho Z.H., Jones J.P., Singh M. *Foundations of Medical Imaging*. Wiley-Interscience, 1993. 600 p.
2. Eisenberg R.L., Margulis A. *A Patient's Guide to Medical Imaging*. Oxford University Press, 2011. 256 p.
3. Hussain S., Mubeen I., Ullah N., Shah S.S.U.D., Khan B.A., Zahoor M., et al. Modern diagnostic imaging technique applications and risk factors in the medical field: a review // *BioMed Research International*. 2022. V. 2022. P. 5164970. <https://doi.org/10.1155/2022/5164970>
4. Kantarcı M., Aydın S., Oğul H., Kızılgöz V. New imaging techniques and trends in radiology // *Diagnostic and Interventional Radiology*. 2025. V. 31. N 5. P. 505–517. <https://doi.org/10.4274/dir.2024.242926>
5. Waheed S., Tahir M.J., Ullah I., Alwalid O., Irshad S.G., Asghar M.S., Yousaf Z. The impact of dependence on advanced imaging techniques on the current radiology practice // *Annals of Medicine and Surgery*. 2022. V. 78. P. 103708. <https://doi.org/10.1016/j.amsu.2022.103708>
6. Wang S., Cao G.H., Wang Y., Liao S., Wang Q., Shi J., et al. Review and prospect: Artificial Intelligence in advanced medical imaging // *Frontiers in Radiology*. 2021. V. 1. P. 781868. <https://doi.org/10.3389/fradi.2021.781868>
7. Khalifa M., Albadawy M. AI in diagnostic imaging: Revolutionising accuracy and efficiency // *Computer Methods and Programs in Biomedicine Update*. 2024. V. 5. P. 100146. <https://doi.org/10.1016/j.cmpbup.2024.100146>
8. Ma J., He Y., Li F., Han L., You C., Wang B. Segment anything in medical images // *Nature Communications*. 2024. V. 15. N 1. P. 654. <https://doi.org/10.1038/s41467-024-44824-z>
9. Ahmadyar Y., Kamali-Asl A., Samimi R., Arabi H., Zaidi H. Automated pulmonary nodule classification from low-dose CT images using ERBNet: an ensemble learning approach // *Medical and Biological Engineering and Computing*. 2025. V. 63. N 9. P. 2767–2779. <https://doi.org/10.1007/s11517-025-03358-2>
10. Ren Y., Liu X., Ge J., Liang Z., Xu X., Grimm L.J., et al. Ipsilateral lesion detection refinement for tomosynthesis // *IEEE Transactions on Medical Imaging*. 2023. V. 42. N 10. P. 3080–3090. <https://doi.org/10.1109/TMI.2023.3280135>
11. Chan H.-P., Samala R.K., Hadjiiski L.M., Zhou C. Deep learning in medical image analysis // *Advances in Experimental Medicine and Biology*. 2020. V. 1213. P. 3–21. [https://doi.org/10.1007/978-3-030-33128-3\\_1](https://doi.org/10.1007/978-3-030-33128-3_1)
12. Gheflati B., Rivaz H. Vision transformers for classification of breast ultrasound images // *Proc. of the 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. 2022. pp. 480–483. <https://doi.org/10.1109/embc48229.2022.9871809>
13. Manigrasso F., Milazzo R., Russo A.S., Lamberti F., Strand F., Pagnani A., Morra L. Mammography classification with multi-view deep learning techniques: Investigating graph and transformer-based architectures // *Medical Image Analysis*. 2025. V. 99. P. 103320. <https://doi.org/10.1016/j.media.2024.103320>
14. Chu X., Tian Z., Wang Y., Zhang B., Ren H., Wei X., Xia H., Shen C. Twins: Revisiting the design of spatial attention in vision transformers // *Proc. of the 35th International Conference on Neural Information Processing Systems*. 2021. P. 9355–9366.
15. Liu Z., Wang Y., Vaidya S., Ruehle F., Halverson J., Soljačić M., Hou T.Y., Tegmark M. KAN: Kolmogorov-Arnold Networks // *arXiv*. 2024. arXiv:2404.19756. <https://doi.org/10.48550/arXiv.2404.19756>

## References

1. Cho Z.H., Jones J.P., Singh M. *Foundations of Medical Imaging*. Wiley-Interscience, 1993, 600 p.
2. Eisenberg R.L., Margulis A. *A Patient's Guide to Medical Imaging*. Oxford University Press, 2011, 256 p.
3. Hussain S., Mubeen I., Ullah N., Shah S.S.U.D., Khan B.A., Zahoor M., et al. Modern diagnostic imaging technique applications and risk factors in the medical field: a review. *BioMed Research International*, 2022, vol. 2022, pp. 5164970. <https://doi.org/10.1155/2022/5164970>
4. Kantarcı M., Aydın S., Oğul H., Kızılgöz V. New imaging techniques and trends in radiology. *Diagnostic and Interventional Radiology*, 2025, vol. 31, no. 5, pp. 505–517. <https://doi.org/10.4274/dir.2024.242926>
5. Waheed S., Tahir M.J., Ullah I., Alwalid O., Irshad S.G., Asghar M.S., Yousaf Z. The impact of dependence on advanced imaging techniques on the current radiology practice. *Annals of Medicine and Surgery*, 2022, vol. 78, pp. 103708. <https://doi.org/10.1016/j.amsu.2022.103708>
6. Wang S., Cao G.H., Wang Y., Liao S., Wang Q., Shi J., et al. Review and prospect: Artificial Intelligence in advanced medical imaging. *Frontiers in Radiology*, 2021, vol. 1, pp. 781868. <https://doi.org/10.3389/fradi.2021.781868>
7. Khalifa M., Albadawy M. AI in diagnostic imaging: Revolutionising accuracy and efficiency. *Computer Methods and Programs in Biomedicine Update*, 2024, vol. 5, pp. 100146. <https://doi.org/10.1016/j.cmpbup.2024.100146>
8. Ma J., He Y., Li F., Han L., You C., Wang B. Segment anything in medical images. *Nature Communications*, 2024, vol. 15, no. 1, pp. 654. <https://doi.org/10.1038/s41467-024-44824-z>
9. Ahmadyar Y., Kamali-Asl A., Samimi R., Arabi H., Zaidi H. Automated pulmonary nodule classification from low-dose CT images using ERBNet: an ensemble learning approach. *Medical and Biological Engineering and Computing*, 2025, vol. 63, no. 9, pp. 2767–2779. <https://doi.org/10.1007/s11517-025-03358-2>
10. Ren Y., Liu X., Ge J., Liang Z., Xu X., Grimm L.J., et al. Ipsilateral lesion detection refinement for tomosynthesis. *IEEE Transactions on Medical Imaging*, 2023, vol. 42, no. 10, pp. 3080–3090. <https://doi.org/10.1109/TMI.2023.3280135>
11. Chan H.-P., Samala R.K., Hadjiiski L.M., Zhou C. Deep learning in medical image analysis. *Advances in Experimental Medicine and Biology*, 2020, vol. 1213, pp. 3–21. [https://doi.org/10.1007/978-3-030-33128-3\\_1](https://doi.org/10.1007/978-3-030-33128-3_1)
12. Gheflati B., Rivaz H. Vision transformers for classification of breast ultrasound images. *Proc. of the 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* 2022. pp. 480–483. <https://doi.org/10.1109/embc48229.2022.9871809>
13. Manigrasso F., Milazzo R., Russo A.S., Lamberti F., Strand F., Pagnani A., Morra L. Mammography classification with multi-view deep learning techniques: Investigating graph and transformer-based architectures. *Medical Image Analysis*, 2025, vol. 99, pp. 103320. <https://doi.org/10.1016/j.media.2024.103320>
14. Chu X., Tian Z., Wang Y., Zhang B., Ren H., Wei X., Xia H., Shen C. Twins: Revisiting the design of spatial attention in vision transformers. *Proc. of the 35th International Conference on Neural Information Processing Systems*, 2021, pp. 9355–9366.

16. Колмогоров А.Н. О представлении непрерывных функций нескольких переменного в виде суперпозиций непрерывных функций одного переменного и сложения // Доклады Академии наук СССР. 1957. Т. 144. № 5. С. 953–956.
17. Yang Z., Zhang J., Luo X., Lu Z., Shen L. Medkan: An advanced Kolmogorov-Arnold Network for medical image classification // Proc. of the IEEE International Conference on Bioinformatics and Biomedicine (BIBM). 2025. P. 3090–3097. <https://doi.org/10.1109/bibm66473.2025.11356561>
18. Shaushenova A., Kuznetsov O., Nurpeisova A., Ongarbayeva M. Implementation of Kolmogorov-Arnold Networks for efficient image processing in resource-constrained Internet of things devices // Technologies. 2025. V. 13. N 4. P. 155. <https://doi.org/10.3390/technologies13040155>
19. Penkin M., Krylov A. FunKAN: Functional Kolmogorov-Arnold Network for medical image enhancement and segmentation // arXiv. 2025. arXiv:2509.13508. <https://doi.org/10.48550/arXiv.2509.13508>
20. Aghaei A.A. fKAN: Fractional Kolmogorov-Arnold Networks with trainable Jacobi basis functions // Neurocomputing. 2025. V. 623. P. 129414. <https://doi.org/10.1016/j.neucom.2025.129414>
21. Yang H., Cai Y., Chen J., Zhang X., Lei W., Shi X., et al. TK-Mamba: marrying KAN with mamba for text-driven 3D medical image segmentation // arXiv. 2025. arXiv:2505.18525. <https://doi.org/10.48550/arXiv.2505.18525>
22. Jaouad T. KANU-Net: Kolmogorov-Arnold Networks based U-Net architecture for images segmentation. 2023 [Электронный ресурс]. URL: [https://github.com/JaouadT/KANU\\_Net](https://github.com/JaouadT/KANU_Net)
23. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // Lecture Notes in Computer Science. 2015. V. 9351. P. 234–241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
24. Seydi S.T. Exploring the potential of polynomial basis functions in Kolmogorov-Arnold Networks: a comparative study of different groups of polynomials // arXiv. 2024. arXiv:2406.02583. <https://doi.org/10.48550/arXiv.2406.02583>
25. Menze B.H., Jakab A., Bauer S., Kalpathy-Cramer J., Farahani K., Kirby J., et al. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS) // IEEE Transactions on Medical Imaging. 2015. V. 34. N 10. P. 1993–2024. <https://doi.org/10.1109/TMI.2014.2377694>
26. Armato S.G., McLennan G., Bidaut L., McNitt-Gray M.F., Meyer C.R., Reeves A.P., et al. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a completed reference database of lung nodules on CT scans // Medical Physics. 2011. V. 38. N 2. P. 915–931. <https://doi.org/10.1118/1.3528204>
27. Al-Dhabyani W., Gomaa M., Khaled H., Fahmy A. Dataset of breast ultrasound images // Data in Brief. 2020. V. 28. P. 104863. <https://doi.org/10.1016/j.dib.2019.104863>
28. Bernal J., Sánchez F.J., Fernández-Esparrach G., Gil D., Rodríguez C., Vilarinho, F. WM-DOVA maps for accurate polyp highlighting in colonoscopy: Validation vs. saliency maps from physicians // Computerized Medical Imaging and Graphics. 2015. V. 43. P. 99–111. <https://doi.org/10.1016/j.compmedimag.2015.02.007>
29. Azad R., Heidary M., Yilmaz K., Huttemann M., Karimijafarbigloo S., Wu Y., Schmeink A., Merhof D. Loss functions in the era of semantic segmentation: a survey and outlook // arXiv. 2023. arXiv:2312.05391. <https://doi.org/10.48550/arXiv.2312.05391>
30. Sun P., Zhang C., Yang Z., Yin F.-F., Liu M. An implicit registration framework integrating Kolmogorov–Arnold Networks with velocity regularization for image-guided radiation therapy // Bioengineering. 2025. V. 12. N 9. P. 1005. <https://doi.org/10.3390/bioengineering12091005>
31. Drokin I. Kolmogorov-Arnold convolutions: design principles and empirical studies // arXiv. 2024. arXiv:2407.01092. <https://doi.org/10.48550/arXiv.2407.01092>
32. Wu Y., Li T., Wang Z., Kang H., He A. TransUKAN: computing-efficient hybrid KAN-transformer for enhanced medical image segmentation // arXiv. 2024. arXiv:2409.14676. <https://doi.org/10.48550/arXiv.2409.14676>
15. Liu Z., Wang Y., Vaidya S., Ruehle F., Halverson J., Soljačić M., Hou T.Y., Tegmark M. KAN: Kolmogorov-Arnold Networks. arXiv. 2024. arXiv:2404.19756. <https://doi.org/10.48550/arXiv.2404.19756>
16. Kolmogorov A.N. On the representation of continuous functions of many variables by superposition of continuous functions of one variable and addition. *Doklady Akademii Nauk SSSR*, 1957, vol. 144, no. 5, pp. 953–956. (in Russian)
17. Yang Z., Zhang J., Luo X., Lu Z., Shen L. Medkan: An advanced Kolmogorov-Arnold network for medical image classification. *Proc. of the IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2025, pp. 3090–3097. <https://doi.org/10.1109/bibm66473.2025.11356561>
18. Shaushenova A., Kuznetsov O., Nurpeisova A., Ongarbayeva M. Implementation of Kolmogorov-Arnold Networks for efficient image processing in resource-constrained Internet of things devices. *Technologies*, 2025, vol. 13, no. 4, pp. 155. <https://doi.org/10.3390/technologies13040155>
19. Penkin M., Krylov A. FunKAN: Functional Kolmogorov-Arnold network for medical image enhancement and segmentation. arXiv, 2025. arXiv:2509.13508. <https://doi.org/10.48550/arXiv.2509.13508>
20. Aghaei A.A. fKAN: Fractional Kolmogorov-Arnold Networks with trainable Jacobi basis functions. *Neurocomputing*, 2025, vol. 623, pp. 129414. <https://doi.org/10.1016/j.neucom.2025.129414>
21. Yang H., Cai Y., Chen J., Zhang X., Lei W., Shi X., et al. TK-Mamba: marrying KAN with mamba for text-driven 3D medical image segmentation. arXiv, 2025. arXiv:2505.18525. <https://doi.org/10.48550/arXiv.2505.18525>
22. Jaouad T. *KANU-Net: Kolmogorov-Arnold Networks based U-Net architecture for images segmentation*. 2023. Available at: [https://github.com/JaouadT/KANU\\_Net](https://github.com/JaouadT/KANU_Net)
23. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Lecture Notes in Computer Science*, 2015, vol. 9351, pp. 234–241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
24. Seydi S.T. Exploring the potential of polynomial basis functions in Kolmogorov-Arnold Networks: a comparative study of different groups of polynomials. arXiv, 2024. arXiv:2406.02583. <https://doi.org/10.48550/arXiv.2406.02583>
25. Menze B.H., Jakab A., Bauer S., Kalpathy-Cramer J., Farahani K., Kirby J., et al. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). *IEEE Transactions on Medical Imaging*, 2015, vol. 34, no. 10, pp. 1993–2024. <https://doi.org/10.1109/TMI.2014.2377694>
26. Armato S.G., McLennan G., Bidaut L., McNitt-Gray M.F., Meyer C.R., Reeves A.P., et al. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a completed reference database of lung nodules on CT scans. *Medical Physics*, 2011, vol. 38, no. 2, pp. 915–931. <https://doi.org/10.1118/1.3528204>
27. Al-Dhabyani W., Gomaa M., Khaled H., Fahmy A. Dataset of breast ultrasound images. *Data in Brief*, 2020, vol. 28, pp. 104863. <https://doi.org/10.1016/j.dib.2019.104863>
28. Bernal J., Sánchez F.J., Fernández-Esparrach G., Gil D., Rodríguez C., Vilarinho, F. WM-DOVA maps for accurate polyp highlighting in colonoscopy: Validation vs. saliency maps from physicians. *Computerized Medical Imaging and Graphics*, 2015, vol. 43, pp. 99–111. <https://doi.org/10.1016/j.compmedimag.2015.02.007>
29. Azad R., Heidary M., Yilmaz K., Huttemann M., Karimijafarbigloo S., Wu Y., Schmeink A., Merhof D. Loss functions in the era of semantic segmentation: a survey and outlook. arXiv, 2023. arXiv:2312.05391. <https://doi.org/10.48550/arXiv.2312.05391>
30. Sun P., Zhang C., Yang Z., Yin F.-F., Liu M. An implicit registration framework integrating Kolmogorov–Arnold Networks with velocity regularization for image-guided radiation therapy. *Bioengineering*, 2025, vol. 12, no. 9, pp. 1005. <https://doi.org/10.3390/bioengineering12091005>
31. Drokin I. Kolmogorov-Arnold convolutions: design principles and empirical studies. arXiv, 2024. arXiv:2407.01092. <https://doi.org/10.48550/arXiv.2407.01092>
32. Wu Y., Li T., Wang Z., Kang H., He A. TransUKAN: computing-efficient hybrid KAN-transformer for enhanced medical image segmentation. arXiv, 2024. arXiv:2409.14676. <https://doi.org/10.48550/arXiv.2409.14676>

## Авторы

**Манжос Геннадий Юрьевич** — аспирант, ассистент, Приволжский исследовательский медицинский университет, Нижний Новгород, 603005, Российская Федерация; Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0009-0007-8551-1908>, [manzhos\\_gy@pimunn.net](mailto:manzhos_gy@pimunn.net)

**Томилов Иван Вячеславович** — старший лаборант, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57772599000](https://orcid.org/0000-0003-1886-2867), <https://orcid.org/0000-0003-1886-2867>, [ivan-tomilov3@yandex.ru](mailto:ivan-tomilov3@yandex.ru)

**Гусарова Наталия Федоровна** — кандидат технических наук, старший научный сотрудник, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57162764200](https://orcid.org/0000-0002-1361-6037), <https://orcid.org/0000-0002-1361-6037>, [nfgusarova@itmo.ru](mailto:nfgusarova@itmo.ru)

**Валитова Юлия Олеговна** — кандидат педагогических наук, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-5345-5461>, [yulia.o.valitova@itmo.ru](mailto:yulia.o.valitova@itmo.ru)

*Статья поступила в редакцию 27.06.2025*

*Одобрена после рецензирования 08.11.2025*

*Принята к печати 23.01.2026*

## Authors

**Gennadiy Yu. Manzhos** — PhD Student, Assistant, Privolzhsky Research Medical University, Nizhny Novgorod, 603005, Russian Federation; ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0009-0007-8551-1908>, [manzhos\\_gy@pimunn.net](mailto:manzhos_gy@pimunn.net)

**Ivan V. Tomilov** — Senior Laboratory Assistant, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57772599000](https://orcid.org/0000-0003-1886-2867), <https://orcid.org/0000-0003-1886-2867>, [ivan-tomilov3@yandex.ru](mailto:ivan-tomilov3@yandex.ru)

**Natalia F. Gusarova** — PhD, Senior Researcher, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57162764200](https://orcid.org/0000-0002-1361-6037), <https://orcid.org/0000-0002-1361-6037>, [nfgusarova@itmo.ru](mailto:nfgusarova@itmo.ru)

**Yulia O. Valitova** — PhD (Education), Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-5345-5461>, [yulia.o.valitova@itmo.ru](mailto:yulia.o.valitova@itmo.ru)

*Received 27.06.2025*

*Approved after reviewing 08.11.2025*

*Accepted 23.01.2026*



Работа доступна по лицензии  
Creative Commons  
«Attribution-NonCommercial»