

МЕТОД СОВМЕЩЕНИЯ ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ НЕЯВНЫХ НЕЙРОННЫХ ПРЕДСТАВЛЕНИЙ НА ОСНОВЕ СЕТЕЙ КОЛМОГОРОВА–АРНОЛЬДА

Дроздов Никита Александрович

Студент

Факультет ВМК МГУ имени М. В. Ломоносова, Москва, Россия

E-mail: drozdovna@my.msu.ru

Научный руководитель — Сорокин Дмитрий Васильевич

Совмещение — одна из ключевых задач обработки медицинских изображений. Ее цель состоит в поиске геометрического преобразования одного из изображений так, чтобы соответствующие области изображений появлялись на них в одном и том же месте. Классические итеративные алгоритмы совмещения [1] хорошо зарекомендовали себя в клинических приложениях, но требуют тщательной настройки параметров для каждой пары и значительных вычислительных затрат. Современные нейросетевые методы совмещения [2] обеспечивают быструю скорость применения, однако зависят от больших обучающих выборок и чувствительны к доменному сдвигу.

Альтернативный подход — неявные нейронные представления (ННП), где деформация параметризуется нейронной сетью, задающей непрерывное отображение координат вокселей в векторы смещений [3]. Сеть оптимизируется отдельно для каждой пары снимков, что снижает зависимость от данных и повышает устойчивость к смене условий. Большинство ННП используют многослойный перцептрон (multi-layer perceptron, MLP) в качестве архитектуры, однако недавно представленные сети Колмогорова–Арнольда (Kolmogorov-Arnold networks, KAN) [4] стали перспективной альтернативой MLP в задачах регрессии.

Нами предлагается метод совмещения KAN-IDIR, в котором ННП реализуется в виде KAN с базисом из полиномов Чебышева. Поле деформации параметризуется как $\Phi(\mathbf{x}) = \mathbf{x} + U(\mathbf{x})$, где U — поле смещений, предсказываемое нейронной сетью. Оптимизация сводится к минимизации функционала потерь $\mathcal{L} = \mathcal{L}_{\text{data}} + \mathcal{L}_{\text{reg}}$, где функция невязки $\mathcal{L}_{\text{data}}$ задается отрицательной кросс-корреляцией, а регуляризатор \mathcal{L}_{reg} включает в себя сглаживающий член и штраф за отрицательный якобиан поля деформации. Для снижения затрат на оптимизацию мы также предлагаем модель RandKAN-IDIR с случайным выбором базиса на каждом слое, что уменьшает число параметров модели без существенной потери качества.

Таблица 1: Результаты на DIR-Lab, OASIS-1 и ACDC. Предложенные нами модели выделены жирным.

Метод	DIR-Lab				OASIS-1	ACDC
	TRE, мм ↓	NJD, % ↓	Время, с ↓	VRAM, Гб ↓	DSC ↑	DSC ↑
pTV	0.95	0.6	442	–	–	–
NODEO	3.93	0.0003	583.5	18.7	0.790	0.795
SINR	4.63	0.002	91.6	21.7	0.760	<i>0.811</i>
IDIR [3]	1.07	0.002	260.8	4.1	0.762	0.814
ccIDIR	1.04	0.002	92.6	1.0	0.779	0.792
KAN-IDIR	<i>0.98</i>	<i>0.0006</i>	<i>63.3</i>	2.2	0.793	0.814
RandKAN-IDIR	0.99	0.006	43.1	<i>1.4</i>	<i>0.792</i>	0.810

Эксперименты проводились на трех наборах данных: DIR-Lab (КТ легких), OASIS-1 (МРТ головного мозга) и ACDC (МРТ сердца). Качество оценивалось по стандартным метрикам для задачи совмещения: Target Relative Error (TRE), Dice Score (DSC) и доле вокселей с отрицательным якобианом деформации (NJD). Наши модели достигают наилучших или лучших в своем классе результатов при наименьших вычислительных затратах. Предложенная нами стратегия случайного выбора базисных функций в модели RandKAN-IDIR позволяет сократить время выполнения и потребление памяти, при этом не теряя в качестве совмещения. Полученные результаты показывают, что разработанные модели являются практичной альтернативой как классическим, так и нейросетевым методам в условиях дефицита данных и требований к воспроизводимости и надежности алгоритма.

Литература

1. Beg M. F., Miller M. I., Trounev A., Younes L. Computing large deformation metric mappings via geodesic flows of diffeomorphisms. *International Journal of Computer Vision*. 2005. V. 61, № 2. P. 139–157.
2. Balakrishnan G., Zhao A., Sabuncu M. R., Gutttag J., Dalca A. V. VoxelMorph: A learning framework for deformable medical image registration. *IEEE Transactions on Medical Imaging*. 2019. V. 38, № 8. P. 1788–1800.
3. Chen H., et al. Implicit neural representations for deformable image registration. *Medical Image Analysis*. 2022. V. 80. P. 102530.
4. Liu Z., et al. Kolmogorov–Arnold Networks. 2024. arXiv:2404.19756.