

УДК 004.932.2

DOI: [10.26102/2310-6018/2025.51.4.046](https://doi.org/10.26102/2310-6018/2025.51.4.046)

Метод регистрации мультифазных КТ-изображений с адаптивной весовой функцией

А.А. Куликов✉

МИРЭА – Российский технологический университет, Москва, Российская Федерация

Резюме. В статье предложен усовершенствованный метод регистрации мультифазных КТ-исследований печени, основанный на модифицированной формуле смещения, объединяющей глобальную аффинную трансформацию, локальную B-spline деформационную модель, адаптивную коррекцию на основе градиента интенсивности и шумовую компоненту для повышения робастности. Ключевым элементом является весовая функция $E(x)$, учитывающая локальные различия в плотности тканей, она ограничивает деформации в плотных структурах и усиливает их в мягких тканях и патологиях. Алгоритм реализован в два последовательных этапа – сначала аффинная, затем B-spline регистрация – с использованием расширенной маски печени и отложенной обрезки изображений, что значительно улучшает сходимость и точность. Эксперименты на наборе из реальных клинических случаев показали превосходство предложенного подхода над стандартными методами. Особенно значимый прирост достигнут для малых патологий (1–1000 вокселей), средний коэффициент DICE вырос с 0,5737 (аффинная регистрация) до 0,6277. Метод демонстрирует высокую устойчивость к артефактам, вызванным дыханием пациента, шумом и неоднородностью контрастирования, а также обеспечивает точное совмещение на границах объектов. Результаты подтверждают клиническую применимость подхода для диагностики, анализа динамики заболеваний печени и планирования лечения.

Ключевые слова: регистрация медицинских изображений, мультифазная КТ-визуализация, печень, аффинная трансформация, B-spline деформация, адаптивная коррекция, шумовая компонента, весовая функция, коэффициент DICE, совмещение патологий.

Для цитирования: Куликов А.А. Метод регистрации мультифазных КТ-изображений с адаптивной весовой функцией. *Моделирование, оптимизация и информационные технологии*. 2025;13(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=2107> DOI: 10.26102/2310-6018/2025.51.4.046

Method for registering multiphase CT images with an adaptive weight function

A.A. Kulikov✉

MIREA – Russian Technological University, Moscow, the Russian Federation

Abstract. The article proposes an improved method for recording multiphase CT scans of the liver, based on a modified displacement formula that combines global affinity transformation, a local B-spline deformation model, adaptive correction based on an intensity gradient and a noise component to increase robustness. The key element is the weight function $E(x)$, which takes into account local differences in tissue density, it limits deformations in dense structures and enhances them in soft tissues and pathologies. The algorithm is implemented in two consecutive stages – first affine, then B-spline registration – using an extended liver mask and deferred cropping of images, which significantly improves convergence and accuracy. Experiments on a set of clinical cases have shown the superiority of the proposed approach over standard methods. A particularly significant increase was achieved for small pathologies (1–1000 voxels), the average DICE coefficient increased from 0.5737 (affinity registration) to 0.6277. The method demonstrates high resistance to artifacts caused by the patient's breathing, noise and contrast inhomogeneity, and also ensures accurate alignment at the boundaries of

objects. The results confirm the clinical applicability of the approach for diagnosis, analysis of liver disease dynamics and treatment planning.

Keywords: medical image registration, multiphase CT imaging, liver, affine transformation, B-spline deformation, adaptive correction, noise component, weight function, DICE coefficient, pathology alignment.

For citation: Kulikov A.A. Method for registering multiphase CT images with an adaptive weight function. *Modeling, Optimization and Information Technology*. 2025;13(4). (In Russ.). URL: <https://moitvivr.ru/ru/journal/pdf?id=2107> DOI: 10.26102/2310-6018/2025.51.4.046

Введение

Совмещение (регистрация) медицинских изображений является ключевым этапом при анализе мультимодальных и мультифазных данных, позволяя корректно совместить изображения одного анатомического объекта, полученные в разное время или при различных условиях сканирования. Это необходимо для комплексной оценки состояния органа, анализа динамики изменения патологий под воздействием контрастного вещества и планирования лечения. Современные подходы к регистрации можно условно разделить на несколько категорий: глобальные трансформации, локальные деформационные модели, адаптивные методы и подходы на основе искусственного интеллекта.

Глобальные трансформации, такие как жесткая и аффинная регистрация, эффективны для компенсации общих изменений положения, ориентации и масштаба. Аффинная трансформация широко используется как начальный этап выравнивания [1], обеспечивая базовое совмещение крупных структур. Однако она не способна учитывать неравномерные деформации мягких тканей, что ограничивает ее применение в клинически сложных сценариях.

Для преодоления этих ограничений применяются локальные деформационные модели. Одним из наиболее распространенных подходов является использование базисных функций B-spline, предложенное в работе [2] в рамках метода свободной деформации. Этот метод строит гладкое деформационное поле на основе контрольной сетки, позволяя описывать сложные локальные изменения формы. Несмотря на высокую гибкость, такие модели требуют аккуратной регуляризации для предотвращения физически неверных деформаций [3].

Для повышения робастности к шуму и артефактам вводятся дополнительные механизмы. В работах по робастной регистрации рассматривается добавление стохастических компонент для снижения влияния выбросов и погрешностей данных [3, 4]. Особое внимание уделяется точности на границах объектов. В этом направлении в работе [5] предложены методы диффузионной регистрации, где градиент интенсивности используется для управления гладкостью деформаций вблизи контуров, что позволяет лучше сохранять форму объектов.

Для количественной оценки качества совмещения используются различные метрики: Mattes Mutual Information (MMI) – наиболее популярная метрика для мультимодальной регистрации; Mean Squares – используется для однофазных изображений с близкой интенсивностью; Correlation – подходит для случаев, где важно сохранение формы сигнала.

В последнее время все большее распространение получают подходы на основе глубокого обучения. Методы, такие как VoxelMorph, демонстрируют высокую скорость и точность, обучаясь на больших наборах данных для прямого предсказания деформационных полей [6]. Параллельно развиваются архитектуры на основе трансформеров, показывая высокую эффективность в задачах 3D-сегментации

медицинских изображений [7]. Кроме того, исследования показывают, что качество сегментации в мультифазных исследованиях напрямую зависит от точности предварительной регистрации, а эффективные схемы слияния изображений могут значительно повысить производительность нейросетевых моделей [8].

Предлагаемый в данной статье подход не основан на глубоком обучении, однако заимствует ключевые идеи из указанных работ: использование B-spline модели для локальных деформаций, учёт градиента интенсивности для работы с границами и введение компоненты, аналогичной шуму, для повышения робастности. На основе этих принципов была разработана модифицированная формула смещения, которая объединяет эти элементы в единую интерпретируемую модель, адаптированную под специфику мультифазных КТ-исследований печени.

Целью данного исследования является разработка и экспериментальная оценка усовершенствованного метода регистрации мультифазных КТ-изображений печени, основанного на модифицированной формуле смещения, объединяющей глобальную аффинную трансформацию, локальную B-spline деформационную модель, адаптивную коррекцию и шумовую компоненту для повышения точности и робастности, особенно при работе с малыми патологиями.

Материалы и методы

На практике стандартные методы регистрации, такие как аффинная трансформация и B-spline деформационная модель, показывают хорошие результаты при работе с крупными анатомическими структурами, например, такими как печень. Однако их эффективность значительно снижается в задачах, где требуется высокая точность совмещения мелких или сложных по форме объектов патологий. Одним из ключевых ограничений существующих подходов является то, что они не учитывают различия в плотности тканей, которые могут существенно влиять на характер деформаций. Например, кости практически не подвержены деформации, однако мягкие ткани, патологии имеют значительную подвижность и изменчивость формы. Это требует индивидуального подхода к разным типам тканей, чего не обеспечивают стандартные алгоритмы. На качество совмещения негативно влияют движения (даже минимальные, такие как дыхание) пациента во время проведения исследования, технические особенности оборудования, зашумленность данных. В таких случаях даже небольшие неточности в положении изображений приводят к снижению метрик качества регистрации, особенно для малых объектов. Стандартные методы оказываются недостаточно устойчивыми к этим факторам, что делает их менее надежными в клинической практике.

Еще одной серьезной проблемой является недостаточная точность регистрации на границах объектов. Методы, основанные на глобальных преобразованиях, часто не справляются с резкими перепадами интенсивности или сложными формами патологических образований. Это связано с тем, что классические алгоритмы не адаптируются к локальным особенностям изображения, таким как неоднородности и нечеткие контуры, что особенно критично при анализе изменения видимости патологий на мультифазных КТ изображениях под влиянием контрастного вещества.

Эти проблемы становятся особенно актуальными при работе с патологиями печени, например, такими как кисты, гемангиомы, карциномы. Они зачастую отличаются малым размером, что затрудняет их обнаружение и точное совмещение; сложной и нерегулярной формой, которая может меняться от фазы к фазе, выраженной неоднородностью интенсивности по фазам контрастирования, что усложняет процесс совмещения.

Таким образом, стандартные подходы к регистрации сталкиваются с рядом трудностей, которые ограничивают их применимость в задачах, требующих высокой точности, особенно при анализе малых и сложных по форме патологий. Для решения этих задач необходимы более продвинутые формулы смещения, способные учитывать локальные особенности, шумы и вариации плотности тканей.

Для устранения вышеупомянутых проблем предлагается использовать модифицированную формулу смещения, объединяющую преимущества глобальной аффинной трансформации и локальной деформационной модели, с добавлением уже известных компонент:

$$T(x) = A(x) + E(x) \cdot \sum_i w_i b_i(x) + \gamma O(x) + \delta P(x), \quad (1)$$

где $A(x) = Mx + t$ – глобальная аффинная трансформация, где M – матрица поворота и масштабирования (3×3), t – вектор смещения (3×1); $\sum_i w_i b_i(x)$ – локальная деформационная модель, представленная как линейная комбинация базисных функций $b_i(x)$ с весами w_i ; w_i – это параметры, которые определяют величину и направление движения при совмещении (оптимизатор начинает с нулевых или малых значений w_i (нет деформации), затем он итеративно обновляет каждый вес w_i , чтобы минимизировать метрику точности; это похоже на обучение: модель «учится» какие деформации нужны для лучшего совмещения); $E(x)$ – локальные весовые коэффициенты, учитывающие вариации плотности тканей ($E(x) \in [0, 1]$); $\gamma O(x)$ – шумовая компонента; $O(x)$ – гауссовский шум, γ – коэффициент интенсивности шума, описанный в работе [1]; $\delta P(x)$ – адаптивная коррекция, описанная в работе [2], где $P(x) = \|\nabla I(x)\|$ – модуль градиента интенсивности, δ – коэффициент влияния коррекции, его действие: чем больше перепад интенсивности пикселей изображения, тем сильнее будет коррекция.

Локальные весовые коэффициенты $E(x)$ рассчитываются на основе локальных свойств изображения, а именно, интенсивности сигнала и модуля градиента интенсивности. Целью является снижение вклада деформационной модели в областях с высокой плотностью тканей и его увеличение в мягких тканях, где допустимы более значительные смещения. Формально функция $E(x)$ определяется следующим образом:

$$E(x) = \frac{1}{1 + \alpha \cdot \|\nabla I(x)\| + \beta \cdot (I_{max} - I(x))}, \quad (2)$$

где $I(x)$ – интенсивность пикселя в точке x ; $\|\nabla I(x)\|$ – модуль градиента интенсивности в точке x ; I_{max} – максимальная интенсивность в изображении; α и β – эмпирические коэффициенты, контролирующие влияние градиента и абсолютной интенсивности соответственно.

Таким образом, в областях с высокой плотностью ($I(x) \approx I_{max}$) знаменатель в формуле (2) растет, и $E(x)$ стремится к нулю, ограничивая деформацию. На границах объектов, где $\|\nabla I(x)\|$ велик, $E(x)$ также уменьшается, предотвращая чрезмерные смещения в сложных участках. В мягких тканях, где интенсивность ниже и градиент невелик, $E(x)$ близко к единице, что позволяет активно применять локальную деформационную модель.

Параметры глобальной аффинной трансформации $A(x) = Mx + t$ не задаются вручную, а оптимизируются автоматически в процессе регистрации. Матрица M и вектор смещения t инициализируются как единичная матрица и нулевой вектор соответственно, после чего корректируются с помощью градиентного метода минимизации метрики ММІ. Оптимизация проводится до достижения сходимости по изменению значения метрики или числу итераций.

Аналогично, веса w_i базисных функций $b_i(x)$ в локальной деформационной модели не фиксируются заранее. Они являются свободными параметрами модели и подбираются

в ходе оптимизации, минимизируя расхождение между фиксированным и подвижным изображениями. Процесс начинается с начального приближения (например, нулевых весов), после чего каждый вес w_i итеративно обновляется на основе производной целевой функции по этому параметру. Это обеспечивает адаптивное построение деформационного поля, наиболее точно соответствующего структуре данных.

Предложенная в статье формула смещения не является полностью новой по своим элементам – все ее компоненты имеют аналоги в литературе. Однако новизна представленного подхода заключается в комбинированном использовании всех этих элементов с учетом специфики медицинских данных печени: разделение на плотные и мягкие ткани через весовую функцию $E(x)$, компенсация артефактов и погрешностей через $\gamma O(x)$, повышение точности на границах объектов через $\delta P(x)$.

Такая комбинация позволяет повысить точность регистрации медицинских изображений, особенно для патологий малого объема, где стандартные методы показывают снижение метрик качества, что влечет за собой неверную постановку диагноза. Опишем подробнее компоненты функции смещения.

Глобальная аффинная трансформация ($Mx + t$) отвечает за общие изменения положения, ориентации и размера объекта. Она необходима для начальной коррекции изображений и обеспечивает базовое совмещение.

Локальная деформационная модель ($E(x) \cdot \sum_i w_i b_i(x)$) учитывает неравномерные искажения внутри объекта, такие как деформации мягких тканей. Это особенно важно для медицинских изображений, где структуры могут быть подвержены значительным изменениям. Дополнительно вводится весовой коэффициент $E(x)$, который позволяет адаптировать трансформацию к локальным свойствам данных. Например, в областях с высокой плотностью смещение должно быть минимальным, а в мягких тканях – более значительным.

В медицинских изображениях часто присутствуют артефакты и погрешности. Для учета этих факторов добавляется шумовая компонента $\gamma O(x)$. Где $O(x)$ – случайная величина, обычно распределенная по гауссовскому шуму, γ – параметр, который контролирует интенсивность шума. Введение этой компоненты позволяет делать алгоритм более робастным к артефактам.

Адаптивная коррекция вычисляется на основе градиента интенсивности и позволяет улучшить совмещение в сложных областях, таких как границы объектов.

Таким образом, предложенный подход использует проверенные на практике элементы, объединяет их в единую формулу смещения, адаптированную под задачи регистрации мультифазных КТ-исследований. Это делает его более точным и устойчивым к клиническим артефактам, чем каждый из существующих методов по отдельности.

Предлагаемый далее алгоритм реализует многоэтапную регистрацию для совмещения мультифазных КТ-изображений печени с использованием библиотеки языка Python SimpleITK. Целью является точное совмещение как масок печени, так и патологий (кист, опухолей) между различными фазами сканирования.

Этап 1. Инициализация и подготовка данных. На данном этапе указывается путь к основному каталогу с исследованиями, после чего программа сканирует его и формирует список исследований печени. Для каждого случая последовательно загружаются фиксированные и подвижные КТ-изображения вместе с соответствующими бинарными масками печени и патологий. Важным шагом предобработки является расширение маски печени с помощью морфологического оператора BinaryDilate, который «размывает» границы маски на заданное число вокселей. Это позволяет увеличить область интереса, учитывая при расчете метрики регистрации не только саму

печень, но и прилегающую зону, что значительно улучшает сходимость алгоритма. Перед началом регистрации выполняется проверка соответствия размеров всех изображений и масок для предотвращения ошибок на последующих этапах.

Этап 2. Аффинная регистрация. Данный этап реализует глобальный компонент модифицированной формулы смещения, а именно глобальную аффинную трансформацию $A(x) = Mx + t$. Регистрация выполняется с использованием метрики Mattes Mutual Information (MMI) [3] и оптимизатора Gradient Descent Line Search (GDLS). Процесс начинается с инициализации параметров аффинной трансформации – матрицы M и вектора t . Затем выполняется итеративная оптимизация этих параметров путем вызова метода `registration_method.Execute(fixed_image, moving_image)` из библиотеки SimpleITK, что возвращает результирующую аффинную трансформацию `affine_transform`. Данная трансформация применяется к подвижному изображению и всем маскам через функцию `sitk.Resample`, в результате чего формируется промежуточное зарегистрированное изображение `moving_resampled_affine`.

Этап 3. B-spline регистрация с использованием модифицированной формулы. На данном этапе выполняется локальное нелинейное выравнивание, которое реализует полную модифицированную формулу смещения. В процессе оптимизации объединяются все ее компоненты: результат глобальной аффинной трансформации $A(x)$, локальная B-spline деформационная модель, взвешенная адаптивной функцией $E(x)$, а также шумовая компонента и адаптивная коррекция, задаваемые через параметры метода. B-spline трансформация инициализируется с использованием результата аффинного этапа в качестве начального приближения. В ходе оптимизации строится деформационное поле, где влияние локальной B-spline модели в каждой точке регулируется весовой функцией $E(x)$, вычисляемой на основе градиента интенсивности и абсолютного значения интенсивности. С помощью метода `registration_method.Execute` с фиксированным и предварительно выровненным изображениями вычисляется окончательная B-spline трансформация. Полученная трансформация применяется через `sitk.Resample` ко всем данным, при этом формируется окончательный результат `moving_resampled_bspline`.

Этап 4. Обрезка (Crop) после регистрации. Важной особенностью предлагаемого алгоритма является отсроченная обрезка данных, выполняемая после полного завершения обоих этапов регистрации. Это позволяет сохранить пространственный контекст в процессе оптимизации. Обрезка осуществляется по ограничивающей рамке, построенной на основе маски печени и расширенной для создания буферной зоны. Данная процедура применяется ко всем зарегистрированным данным – КТ-изображениям и маскам, обеспечивая компактное представление результатов без потери точности выравнивания.

Этап 5. Оценка качества регистрации. После применения трансформаций выполняется оценка качества регистрации с использованием коэффициента DICE в качестве основной метрики. Для каждой пары совмещенных масок печени и патологий на обоих этапах (аффинном и B-spline) вычисляется значение DICE по формуле:

$$DICE = \frac{2 \cdot |A \cap B|}{|A| + |B|},$$

после чего рассчитывается среднее значение Average DICE по всем случаям. Полученные результаты сохраняются для последующего анализа.

Этап 6: Генерация PDF-отчета. На завершающем этапе генерируется детальный PDF-отчет, содержащий общую статистику выполнения скрипта, гистограммы распределения метрик DICE и сводную таблицу результатов, сгруппированных по объемам патологий. Для каждого случая формируется индивидуальная страница с

параметрами исследования (номер печени, фазы, объем патологии) и 3D-рендерами, визуализирующими качество совмещения масок. Процесс полностью автоматизирован от регистрации до визуализации результатов.

Результаты и обсуждение

Для оценки эффективности модифицированной формулы был проведен ряд экспериментов на наборе медицинских изображений, состоящем из 65 исследований.

Для экспериментов использовались данные мультифазных КТ-снимков печени, предоставленные Центром диагностики и телемедицины (ЦДиТ)¹. Снимки были размечены специалистами для сегментации четырех классов патологий. Каждое исследование включало 3D изображения артериальной (ART) и венозной (PV) фазы введения контрастного вещества, полученные для одного и того же пациента. Целью эксперимента было сравнение точности совмещения изображений с использованием стандартной аффинной трансформации и модифицированной формулы смещения. Набор данных включал медицинские КТ-снимки брюшной полости, представленные в формате NIfTI (.nii.gz), бинарные маски печени и патологий кист, и результаты сегментации патологий печени обученной моделью nnUnet [9]. Для повышения точности сегментации малых патологий в таких моделях применяется функция потерь [10] это актуально при несбалансированном распределении классов. При подготовке данных был применен препроцессинг, который включал в себя нормализацию изображений для устранения различий в интенсивностях, для каждого из исследований выбрана фиксированная (опорная) фаза, к которой необходимо было смещать другую фазу.

Для оценки эффективности предложенной модифицированной формулы смещения была проведена серия экспериментов, включающих количественный анализ метрик качества. Результаты, представленные в Таблице 1, демонстрируют последовательное преимущество модифицированного метода во всех диапазонах объемов патологий.

Таблица 1 – Результаты сравнительного анализа
 Table 1 – The results of the comparative analysis

Объем патологии (вокселей)	Количество случаев в выборке	Модифицир. формула Average DICE	Простой Bspline метод Average DICE	Простая аффинная трансформация Average DICE
1–1000	13	0,6277	0,5964	0,5737
1001–5000	17	0,7705	0,7651	0,7349
5001–10000	6	0,8435	0,8238	0,7984
10001–50000	13	0,8401	0,8343	0,7728
50001–150000	4	0,9269	0,9230	0,9122
150001–300000	4	0,9434	0,9358	0,9468
300000+	9	0,9503	0,9459	0,9338

Наиболее значительное улучшение наблюдается в группе малых объемов (1–1000 вокселей), где показатель DICE увеличился на 0,054 по сравнению с аффинной трансформацией. Модифицированная формула также превзошла стандартный B-spline метод во всех категориях, что подтверждает эффективность введенных улучшений. С увеличением объема патологий разница между методами уменьшается, однако предложенный подход сохраняет стабильное преимущество, достигая значения DICE

¹ Васильев Ю.А., Арзамасов К.М., Пестренин Л.Д. и др. MosMedData: КТ с наличием и отсутствием признаков образований печени и их сегментацией: заявл. 13.12.2024; опубл. 18.12.2024. Свидетельство о государственной регистрации базы данных № RU 2024626116.

0,9503 для больших образований. Особый интерес представляет случай в диапазоне 150001–300000 вокселей, где аффинная трансформация показала несколько лучший результат, что может быть связано с особенностями формы и расположения патологий в данной выборке. В целом, результаты подтверждают, что модифицированная формула обеспечивает более точное совмещение изображений, особенно для малых и средних по объему патологий.

На Рисунке 1 представлено сравнение совмещения PV-фазы с фиксированной ART-фазой для двух подходов: модифицированной формулы смещения (слева) и стандартной аффинной трансформации (справа). Модифицированная формула, объединяющая глобальную аффинную трансформацию, локальную деформационную модель, шумовую компоненту и адаптивную коррекцию, демонстрирует высокую точность совмещения с коэффициентом DICE 0,8432 для печени и 0,8495 для патологии. В отличие от этого, стандартный подход, учитывающий только глобальные изменения, показывает значительно более низкую точность для патологий (DICE = 0,5308), хотя и сохраняет приемлемые результаты для печени (DICE = 0,9671). Визуальное сравнение подтверждает преимущество предложенного метода, особенно в сложных областях с неоднородными деформациями.




Рисунок 1 – Сравнение результатов стандартного (справа) и предлагаемого (слева) подхода
Figure 1 – Comparison of the results of the standard (right) and proposed (left) approaches

Заключение

В работе предложен усовершенствованный метод регистрации мультифазных КТ-изображений печени, основанный на модифицированной формуле смещения. Разработанный подход устраняет принципиальные ограничения стандартных методов, сочетая глобальную аффинную трансформацию с комплексной локальной коррекцией, включающей B-spline деформационную модель, шумовую компоненту и адаптивную градиентную коррекцию. Ключевым элементом системы является адаптивная весовая функция $E(x)$, обеспечивающая дифференцированный подход к деформации различных типов тканей.

Экспериментальная оценка на выборке из 65 клинических случаев продемонстрировала статистически значимое улучшение точности регистрации по сравнению с классическими методами. Наиболее существенный прирост точности зафиксирован для малых патологий объемом 1–1000 вокселей, где значение коэффициента DICE увеличилось с 0,5737 до 0,6277. Для средних и крупных образований также наблюдается устойчивое улучшение метрик, подтверждающее эффективность предложенных модификаций.

Полученные результаты обосновывают клиническую применимость метода для задач диагностики, мониторинга динамики патологических процессов и планирования хирургических вмешательств. В дальнейшем планируется разработка автоматизированной системы оптимизации параметров модели и интеграция с современными нейросетевыми архитектурами [11] для повышения точности и эффективности обработки медицинских изображений.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Zitová B., Flusser J. Image Registration Methods: A Survey. *Image and Vision Computing*. 2003;21(11):977–1000. [https://doi.org/10.1016/S0262-8856\(03\)00137-9](https://doi.org/10.1016/S0262-8856(03)00137-9)
2. Rueckert D., Sonoda L.I., Hayes C., Hill D.L.G., Leach M.O., Hawkes D.J. Nonrigid Registration Using Free-Form Deformations: Application to Breast MR Images. *IEEE Transactions on Medical Imaging*. 1999;18(8):712–721. <https://doi.org/10.1109/42.796284>
3. Avants B.B., Epstein C.L., Grossman M., Gee J.C. Symmetric Diffeomorphic Image Registration with Cross-Correlation: Evaluating Automated Labeling of Elderly and Neurodegenerative Brain. *Medical Image Analysis*. 2008;12(1):26–41. <https://doi.org/10.1016/j.media.2007.06.004>
4. Vercauteren T., Pennec X., Perchant A., Ayache N. Symmetric Log-Domain Diffeomorphic Registration: A Demons-Based Approach. In: *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2008: 11th International Conference: Proceedings, Part I, 06–10 September 2008, New York, USA*. Berlin, Heidelberg: Springer; 2008. P. 754–761. https://doi.org/10.1007/978-3-540-85988-8_90
5. Fischer B., Modersitzki J. Fast Diffusion Registration. *AMS Contemporary Mathematics, Inverse Problems, Image Analysis, and Medical Imaging*. 2002;313:117–127. <https://doi.org/10.1090/conm/313/05372>
6. 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;38(8):1788–1800. <https://doi.org/10.1109/TMI.2019.2897538>
7. Hatamizadeh A., Tang Yu., Nath V., et al. UNETR: Transformers for 3D Medical Image Segmentation. In: *2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), 03–08 January 2022, Waikoloa, HI, USA*. IEEE; 2022. P. 1748–1758. <https://doi.org/10.1109/WACV51458.2022.00181>
8. Guo Zh., Li X., Huang H., Guo N., Li Q. Medical Image Segmentation Based on Multi-Modal Convolutional Neural Network: Study on Image Fusion Schemes. In: *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), 04–07 April 2018, Washington, DC, USA*. IEEE; 2018. P. 903–907. <https://doi.org/10.1109/ISBI.2018.8363717>
9. Куликов А.А., Каширина И.Л., Савкина Е.Ф. Сегментация объемных образований печени на мультифазных КТ-изображениях с использованием фреймворка nnU-Net. *Моделирование, оптимизация и информационные технологии*. 2025;13(1). <https://doi.org/10.26102/2310-6018/2025.48.1.040>
Kulikov A.A., Kashirina I.L., Savkina E.F. Segmentation of Liver Volumetric Lesions in Multiphase CT Images Using the nnU-Net Framework. *Modeling, Optimization and Information Technology*. 2025;13(1). (In Russ.). <https://doi.org/10.26102/2310-6018/2025.48.1.040>
10. Salehi S.S.M., Erdogmus D., Gholipour A. Tversky Loss Function for Image Segmentation Using 3D Fully Convolutional Deep Networks. In: *Machine Learning in Medical Imaging: 8th International Workshop – MLMI 2017, Held in Conjunction with*

- MICCAI 2017, 10 September 2017, Quebec City, QC, Canada.* Cham: Springer; 2017. P. 379–387. https://doi.org/10.1007/978-3-319-67389-9_44
11. Khoong W.H. BUSU-Net: An Ensemble U-Net Framework for Medical Image Segmentation. arXiv. URL: <https://arxiv.org/abs/2003.01581> [Accessed 10th September 2025].

ИНФОРМАЦИЯ ОБ АВТОРЕ / INFORMATION ABOUT THE AUTHOR

Куликов Александр Анатольевич, старший преподаватель кафедры технологий искусственного интеллекта, МИРЭА – Российский технологический университет, Москва, Российская Федерация.
e-mail: kulikov_aa@mirea.ru
ORCID [0000-0002-8443-3684](https://orcid.org/0000-0002-8443-3684)

Alexander A. Kulikov, Senior Lecturer at the Department of Artificial Intelligence Technologies, MIREA – Russian Technological University, Moscow, the Russian Federation.

Статья поступила в редакцию 18.10.2025; одобрена после рецензирования 21.11.2025; принята к публикации 27.11.2025.

The article was submitted 18.10.2025; approved after reviewing 21.11.2025; accepted for publication 27.11.2025.