

УДК 004.93'11:616-073.75

 10.25209/2079-3316-2026-17-2-147-190

## Интеграция многомасштабных признаков и механизмов внимания для сегментации колоректальных опухолей на компьютерных томограммах

Юйцянь Ван<sup>1✉</sup>, Сергей Владимирович Аксёнов<sup>2</sup><sup>1, 2</sup>Школа информационных технологий и робототехники, Томский политехнический университет, Томск, Россия<sup>2</sup>Томский государственный университет систем управления и радиоэлектроники, Томск, Россия✉ [wangyuqian3333@gmail.com](mailto:wangyuqian3333@gmail.com)

**Аннотация.** В последние годы технологии глубокого обучения получили широкое применение в области анализа медицинских изображений, демонстрируя выдающиеся результаты, особенно в задачах сегментации.

В связи с проблемой потери семантической информации на этапе извлечения признаков в U-образных сетях, что ограничивает точность сегментации опухолей прямой кишки, в данной работе на основе архитектуры U-Net предложена новая модель сегментации, получившая название MGA-UNet (Multi-scale Ghost Attention U-Net). Модель объединяет многомасштабное извлечение признаков, механизмы двойного (канального и пространственного) внимания и блоки управления вниманием (Attention Gate) в пропускных соединениях. Основные улучшения заключаются в следующем:

Во-первых, на этапе кодирования используется усовершенствованный модуль Ghost (интегрированный с RFB) для извлечения и слияния признаков на различных масштабах.

Во-вторых, в путь кодирования внедрён модуль внимания СВМ для усиления отклика сети на малоразмерные целевые объекты.

В-третьих, в пропускные соединения встроены блоки управления вниманием для подавления нерелевантных фоновых областей и выделения характеристик опухоли.

Результаты тестирования на наборе КТ-данных колоректального рака показали высокую эффективность предложенной модели. По сравнению с классическими моделями U-Net, GhostNet, а также современными архитектурами Mamba-UNet и U-SAM, предложенная модель обеспечивает более точную локализацию границ опухоли прямой кишки и демонстрирует превосходное качество сегментации. Эффективность и стабильность каждого модуля подтверждены в ходе абляционных исследований и анализа чувствительности гиперпараметров.

**Ключевые слова и фразы:** U-Net, механизм внимания, пропускные соединения, сегментация изображений, MGA-UNet

**Благодарности:** Работа выполнена при поддержке Китайского стипендиального совета (CSC) (грант № 202008410491).

**Для цитирования:** Ван Ю., Аксёнов С. В. *Интеграция многомасштабных признаков и механизмов внимания для сегментации колоректальных опухолей на компьютерных томограммах* // Программные системы: теория и приложения. 2026. Т. 17. № 2(71). С. 147–190. [https://psta.psiras.ru/read/psta2026\\_2\\_147-190.pdf](https://psta.psiras.ru/read/psta2026_2_147-190.pdf)

## Введение

Согласно отчёту о мировой статистике рака за 2024 год, колоректальный рак занимает третье место в мире по показателям заболеваемости и второе место среди причин смертности от онкологических заболеваний [1]. Клинические характеристики заболевания тесно связаны с типом, локализацией, размером и количеством колоректальных полипов. Раннее выявление и удаление полипов играет ключевую роль в снижении заболеваемости колоректальным раком и значительно улучшает прогноз выживаемости пациентов.

В настоящее время колоноскопия является основным методом обнаружения колоректальных полипов. Однако результаты многочисленных систематических обзоров и мета-анализов показывают, что при колоноскопии сохраняется существенный риск пропуска полипов и аденом [2]. Таким образом, разработка технологий автоматизированной сегментации колоректальных опухолей не только способствует значительному повышению точности диагностики, но и снижает нагрузку на медицинский персонал, содействуя продвижению программ раннего скрининга и вмешательства.

В последние годы стремительное развитие глубокого обучения обеспечило мощную технологическую поддержку для автоматической сегментации медицинских изображений.

Shelhamer и др. предложили полносвёрточную сеть (FCN), в которой полносвязные слои традиционных CNN заменены свёрточными слоями, а для восстановления разрешения изображений используются операции деконволюции (обратной свёртки), при этом вводятся пропускные соединения (skip connections) для слияния семантической информации мелких и глубоких слоев, что позволяет получать более детализированные результаты сегментации [3].

Ben-Cohen и др. впервые применили FCN для сегментации печени и обнаружения ее повреждений, достигнув среднего коэффициента Dice 0,89 без использования сложных этапов предобработки, что превзошло результаты традиционных CNN [4].

Isensee и др. разработали метод nnU-Net с автоматической конфигурацией, способный адаптивно настраиваться под различные задачи сегментации медицинских изображений [5].

Chen и др. представили сеть EfficientNet-Lite UNet для сегментации биомедицинских изображений, которая обеспечивает высокое качество сегментации при экономии вычислительных ресурсов [6].

Schenk и др. усовершенствовали архитектуру FCN, введя длинные и короткие пропускные соединения для передачи карт признаков из пути сжатия в путь расширения, что позволило восстановить детали, утраченные в процессе субдискретизации, и ускорить сходимость обучения [7].

Iqbal и Sharif предложили метод полуавтоматической сегментации опухолей молочной железы на основе U-образной пирамидальной сети с расширенными свёртками (dilation networks), повысив эффективность сегментации за счет совместного использования размеченных и неразмеченных данных [8].

Ronneberger и др. представили классическую модель U-Net с симметричной структурой кодировщика-декодировщика, которая достигла отличных результатов сегментации благодаря интеграции карт признаков через пропускные соединения [9].

Zhou и др. на основе U-Net разработали U-Net++, в которой за счёт реорганизации пропускных соединений извлекается более богатая иерархическая информация, что минимизирует семантический разрыв между признаками на этапах повышения и понижения дискретизации [10].

Seo и др. предложили сеть mu-U-Net, добавив дополнительные слои деконволюции и функции активации в пропускные соединения для одновременного извлечения глобальных признаков высокого уровня малых объектов и информации о границах высокого разрешения крупных объектов [11].

Wang и др. разработали модель Retina UNet для локализации опухолей головы и шеи на изображениях ПЭТ/КТ, которая не только повышает точность сегментации, но и прогнозирует время выживания пациентов [12].

Кроме того, лёгкие свёрточные сети, такие как GhostNet [13] и ShuffleNetV2 [14], способны значительно снизить вычислительные затраты при сохранении высокой точности, предлагая новые подходы для клинического внедрения сегментации медицинских изображений.

В задачах сегментации колоректальных опухолей колебания качества КТ-изображений затрудняют точную идентификацию границ небольших новообразований. Для решения этой проблемы в данной работе предложен метод сегментации, сочетающий многомасштабные свёртки и механизмы каналльно-пространственного внимания:

- (1) для извлечения многоуровневых признаков традиционные свёрточные операторы заменены модулем многомасштабной свёртки (Ghost+RFB).
- (2) между путями понижения и повышения дискретизации встроен механизм пространственно-канального внимания (СВАМ) для усиления способности сети воспринимать малые объекты.
- (3) в пропускные соединения внедрены блоки управления вниманием (Attention Gate) для фильтрации и слияния ключевой признаковой информации.

Экспериментальные данные подтверждают, что предложенный метод эффективно повышает точность сегментации небольших опухолей.

Параллельно с этим модели на основе трансформеров, такие как ViT [15], TransUNet [16], UNETR [17] и Medical Transformer [18], также достигли успеха в сегментации медицинских изображений, используя механизмы самовнимания для захвата глобального контекста.

Предложенная в данной работе модель MGA-UNet дополняет методы на основе трансформеров, фокусируясь на сочетании легковесных многомасштабных свёрток и блоков управления вниманием, что делает ее более подходящей для сред с ограниченными вычислительными ресурсами.

Недавние исследования, такие как MSGU-Net [19], GA-UNe [20] и MGTUNet [21], также предпринимали попытки внедрения многомасштабных структур или механизмов внимания в U-образную архитектуру. Однако в этих работах либо отсутствует одновременное сочетание канального и пространственного внимания, либо не предусмотрены обучаемые механизмы управления в пропускных соединениях, а сами модели в основном применяются для сегментации поражений кожи или опухолей печени.

Предложенная модель MGA-UNet впервые обеспечивает беспшовную интеграцию многомасштабного модуля Ghost+RFB, двойного внимания CBAM и блоков Attention Gate. Это позволяет эффективно решать такие проблемы КТ-изображений колоректальных опухолей, как малый размер объектов и низкая контрастность границ, обеспечивая значительное повышение точности сегментации при низких вычислительных затратах.

## 1. Методы

### 1.1. Улучшенный свёрточный модуль

Реализация задач сегментации с использованием свёрточных нейронных сетей сопряжена со значительной вычислительной трудоёмкостью, что обусловлено генерацией большого объема избыточных карт признаков. Избыточность проявляется в двух аспектах:

- (1) часть сформированных карт содержит минимальный объем релевантной информации, что ведёт к нерациональному расходу ресурсов.
- (2) высокая степень сходства между отдельными картами признаков (дублирование) существенно увеличивает время обработки данных.

С целью оптимизации процесса генерации высококачественных признаков при минимизации аппаратных затрат Nan и др. разработали облегчённую архитектуру GhostNet [13]. Ключевым элементом данной сети является модуль Ghost, принцип работы которого основан на первоначальном формировании базового набора карт признаков посредством стандартной свёртки с последующим применением экономичных линейных преобразований для получения их аналогов. Такой подход позволяет

радикально сократить вычислительные издержки (структурная схема представлена на рисунке 1).




Рисунок 1. Структура свёртки Ghost

В сравнении с традиционными свёрточными операциями, модуль Ghost позволяет эффективно минимизировать структурную сложность модели и снизить вычислительные затраты, ускоряя процесс обучения без существенной потери качества сегментации. Тем не менее, на втором этапе работы модуля Ghost генерация карт признаков детерминирована исключительно линейными преобразованиями, что ограничивает репрезентативность и разнообразие признаков, потенциально снижая итоговую точность сегментации.

Для наделения модуля Ghost способностью к извлечению многомасштабных признаков в настоящей работе интегрирован блок рецептивного поля (RFB) [22]. Модифицированная структура свёртки Ghost, предложенная авторами, представлена на рисунке 2.

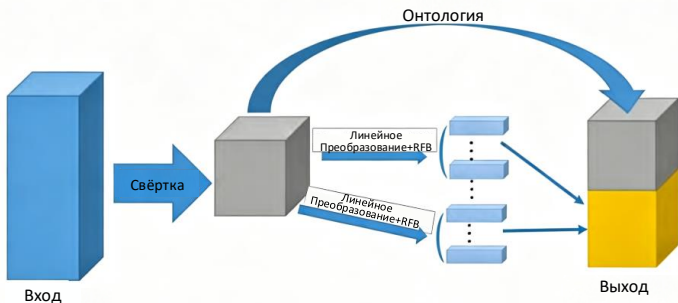


Рисунок 2. Улучшенная свёрточная структура Ghost+RFB

Архитектура блока RFB реализована в виде четырёх параллельных ветвей, включающих свёртку  $1 \times 1$ , а также три типа расширенных (atrous) свёрток:  $3 \times 3$  с коэффициентом расширения (dilation rate) 1,  $3 \times 3$  с коэффициентом 3 и  $5 \times 5$  с коэффициентом 5. Выходные данные всех ветвей объединяются по каналальной размерности (конкатенация), после чего выполняется их поэлементное суммирование с исходным выходом модуля Ghost. Подобная проектная стратегия позволяет модели одновременно экстрагировать локальные детали и учитывать контекстуальную информацию в более широком диапазоне рецептивного поля.

На основе модернизированного модуля Ghost+RFB в данной работе сконструирован обновлённый свёрточный блок, предназначенный для замены стандартных свёрточных компонентов в классической архитектуре U-Net (подробная схема представлена на рисунке 3).




РИСУНОК 3. Улучшенная свёрточная структура

В математическом представлении, при входной карте признаков  $X$ , традиционная свёртка задействует  $K$  фильтров для генерации  $M$  выходных карт. Вычислительная сложность данного процесса (FLOPs) выражается формулой  $H \times W \times M \times k \times k \times C$ , где  $k$  обозначает пространственный размер ядра свёртки. В отличие от этого, модуль Ghost реализует двухэтапную стратегию: на первом этапе формируется  $M'$  базовых карт признаков ( $M' < M$ ), а на втором – к каждой из них применяется  $s$  экономичных линейных преобразований. В результате синтезируется  $M = M' \times s$  карт признаков, при этом вычислительные затраты сокращаются примерно до  $1/s$  от объема стандартной свёртки [13].

В предложенной модификации с блоком RFB этап экономичных преобразований заменён расширенными свёртками с варьируемыми коэффициентами, что существенно расширяет многомасштабное рецептивное поле [23].

Как показано на рисунке 3, предложенный свёрточный блок состоит из двух последовательно соединённых модулей Ghost+RFB. Для нивелирования проблемы деградации глубоких моделей в структуру интегрирована остаточная связь [24]. В процессе реализации после каждого модуля Ghost+RFB применяется пакетная нормализация (BN), при этом функция активации ReLU задействована исключительно после первого модуля. Выход данной структуры  $Y$  формализуется следующим образом:

$$Y = \text{ReLU}(G_2(G_1(X))) + X$$

где  $G_1, G_2$  обозначают каскадную операцию двух модулей Ghost+RFB.

### 1.2. Механизм внимания СВАМ

Механизмы внимания являются эффективным инструментом повышения производительности свёрточных нейронных сетей. За счет дифференцированного взвешивания они позволяют подавлять признаки нерелевантных областей, фокусируя вычислительные ресурсы на наиболее информативных фрагментах данных. В данной работе интегрирован модуль внимания СВАМ (Convolutional Block Attention Module) [25], который последовательно экстрагирует признаки в канальном и пространственном измерениях. Путем поэлементного умножения полученных карт внимания с входными признаками достигается адаптивное уточнение (refinement) признаковых представлений. Структурная схема модуля СВАМ представлена на рисунке 4.




Рисунок 4. Структура модуля СВАМ

Для промежуточной карты признаков  $F \in \mathbb{R}^{H \times W \times C}$  модуль СВАМ последовательно генерирует одномерную карту канального внимания  $M_c \in \mathbb{R}^{1 \times 1 \times C}$  и двумерную карту пространственного внимания  $M_s \in \mathbb{R}^{H \times W \times 1}$ . Процесс обработки описывается следующими выражениями:

$$F' = M_c(F) \otimes F, \quad F'' = M_s(F') \otimes F'$$

где  $\otimes$  обозначает операцию поэлементного умножения.

Механизм канального внимания осуществляет агрегацию пространственных признаков посредством совместного использования слоев

усредняющего (Average Pooling) и максимального (Max Pooling) пула. В свою очередь, блок пространственного внимания генерирует адаптивные весовые коэффициенты, опираясь на глобальные дескрипторы вдоль канальной размерности. Интеграция подобной бимодальной системы внимания позволяет модели с более высокой точностью локализовать области колоректальных новообразований. Несмотря на незначительное увеличение количества обучаемых параметров, прирост точности сегментации, обеспечиваемый модулем СВМ, полностью оправдывает дополнительные вычислительные затраты.

### 1.3. Модификация пропускных соединений

Для модернизации стандартных пропускных соединений в данной работе интегрирован механизм управления вниманием (Attention Gate, AG), предложенный Oktay и др. [26]. Принцип работы AG основан на совместном анализе вектора входных признаков и стробирующего сигнала (gating signal), которые подвергаются линейному преобразованию для выравнивания размерности с последующим поэлементным суммированием. Полученный результат проходит через функцию активации ReLU и вторичное линейное преобразование для снижения размерности. Далее, с помощью сигмоидной функции рассчитываются коэффициенты внимания  $\alpha$ , которые используются для поэлементного взвешивания входного вектора признаков  $\hat{x}$ .

Вычисление вентиля внимания можно формализовать следующим образом:

$$q = \Psi^T(\sigma_1(W_x^T x + W_g^T g + b_g)) + b_\psi,$$

где

$x$  – признаки кодировщика, передаваемые по пропускному соединению,

$g$  – управляющий сигнал из декодировщика,

$\sigma_1$  – ReLU,

$\sigma_2$  – сигмоид,

$W_x, W_g, \Psi$  – обучаемые матрицы,

$b_g, b_\psi$  – базовые смещения.

Вентиль внимания способен автоматически подстраиваться под различные формы и размеры колоректальных опухолей, определяя по коэффициентам внимания, принадлежит ли пиксель области интереса, тем самым подавляя нерелевантные фоновые области и усиливая полезные для конкретной задачи признаки.

### 1.4. Архитектура сети

Архитектура разработанной модели, представленная на рисунке 5, базируется на структуре U-Net. Основные модификации включают

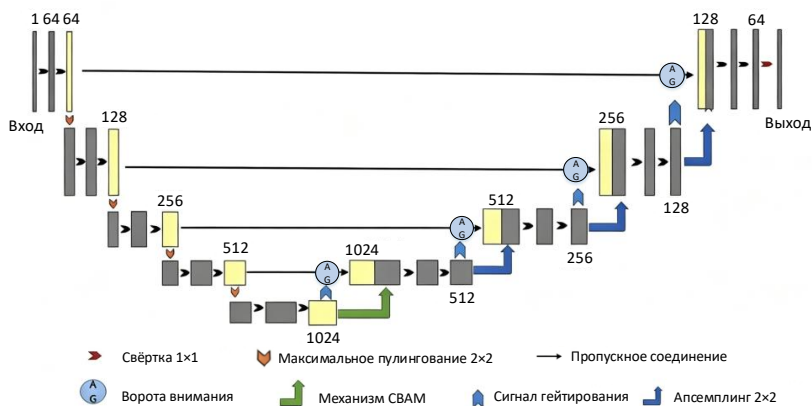


Рисунок 5. Архитектура сети MGA-UNet

замену стандартных свёрточных блоков на усовершенствованные модули Ghost+RFB, интеграцию механизмов управления вниманием (Attention Gate) в пропускные соединения, а также внедрение блоков СВАМ в пути кодирования и декодирования.

В классической сети U-Net процесс сжатия включает четыре этапа субдискретизации. В предложенной модели также реализованы четыре уровня кодирования, однако каждый из них состоит из двух последовательных модулей Ghost+RFB. В рамках каждого модуля входные данные сначала подвергаются первичной свёртке, после чего применяются «экономичные» операции для генерации избыточных карт признаков. Параллельно с этим блок RFB, использующий ядра различных размеров, формирует многомасштабные признаки.

Для стабилизации обучения применяется пакетная нормализация (BN), а функция активации ReLU задействована только после первого модуля Ghost+RFB. Результаты двух модулей объединяются через остаточную связь (residual connection). Завершается каждый этап кодирования операцией максимального пула (Max Pooling) с шагом 2.

В декодировщике содержатся четыре операции повышающей дискретизации. Каждый уровень включает транспонированную свёртку с шагом 2 и два последовательных модуля Ghost+RFB, между которыми применяются нормализация и ReLU. Затем остаточный блок объединяет мелкие и глубокие признаки, предотвращая деградацию сети. В пропускные соединения добавлен механизм внимания, который присваивает различные веса признакам, генерируемым кодировщиком и декодировщиком, тем

самым выделяя информацию, относящуюся к области колоректальной опухоли.

Функция потерь всей сети представляет собой комбинацию бинарной кросс-энтропии (ВСЕ) и Dice-потери:

$$L = \beta \cdot L_{\text{ВСЕ}} + (1 - \beta) \cdot L_{\text{Dice}}, \quad \beta = 0.5,$$

где

$$L_{\text{ВСЕ}} = -\frac{1}{N} \sum_{i=1}^N [y_i \log p_i + (1 - y_i) \log(1 - p_i)],$$

$$L_{\text{Dice}} = 1 - \frac{2 \sum y_i p_i + \epsilon}{\sum y_i + \sum p_i + \epsilon}$$

где

$y_i$  – истинная метка пикселя,

$p_i$  – предсказанная вероятность,

$N$  – общее число пикселей,

$\beta$  – балансирующий вес (в данной работе  $\beta=0.5$ ),

$\epsilon$  – малая константа для предотвращения деления на ноль.

Комбинирующая функция потерь способствует смягчению проблемы дисбаланса классов и повышению точности выделения границ.

## 2. Экспериментальные результаты и анализ

### 2.1. Набор данных и предварительная обработка

Экспериментальные исследования в данной работе проводились на базе набора данных КТ-изображений рака прямой кишки, собранного в Первой аффилированной больнице Университета науки и технологий Хэнань (Лоян, Китай). Исходная выборка включает 2D КТ-сканы 108 пациентов, из которых 1693 изображения содержат экспертную разметку (маски) опухолей. В результате применения методов аугментации данных объем обучающей выборки был расширен до 3057 изображений. Процедура предварительной обработки включала следующие этапы:

- Кадрирование: изображения были обрезаны до размера  $512 \times 512$  с центрированием по области новообразования.
- Коррекция интенсивности: диапазон значений Хаунсфилда (HU) был ограничен пределами  $[-200, 200]$  для улучшения визуализации мягких тканей [27].
- Улучшение контрастности: для повышения дифференциации опухолевой ткани использовался метод выравнивания гистограммы (histogram equalization).

- Нормировка: для минимизации межиндивидуальной вариативности применена нормализация данных, после чего разрешение всех сканов было приведено к стандарту  $256 \times 256$  пикселей.

Набор данных был разделен на обучающую, валидационную и тестовую выборки в соотношении 8 : 1 : 1 соответственно. Визуальное сравнение изображений до и после этапа предобработки представлено на рисунке 6.




РИСУНОК 6. Предобработка КТ-изображений колоректальной опухоли

## 2.2. Метрики и настройки эксперимента

Все экспериментальные исследования реализованы на языке Python 3.9 с использованием фреймворка PyTorch 1.12 [28] в среде разработки PyCharm. Вычисления проводились под управлением ОС Windows 10 на аппаратной платформе, включающей процессор AMD Ryzen 5900X и графический ускоритель NVIDIA GeForce RTX 3080 (10 ГБ видеопамяти). Инициализация весов модели осуществлялась по методу Кайминга (Kaiming Normal) без использования предобученных весов.

Для оптимизации применялся алгоритм AdamW с начальной скоростью обучения  $10^{-4}$  и коэффициентом затухания весов  $10^{-5}$  при размере пакета (batch size) 8. В качестве функционала потерь использована взвешенная комбинация бинарной кросс-энтропии (BCE) и потерь Dice с коэффициентом  $\beta = 0.5$ . Изменение скорости обучения регулировалось по стратегии косинусного отжига ( $T_{max} = 100$  эпох), коэффициент Dropout составил 0.5. Для предотвращения переобучения применена стратегия ранней остановки (Early Stopping): обучение прекращалось, если метрика Dice на валидационном наборе не демонстрировала роста в течение 15 последовательных эпох.

Для объективной верификации эффективности сегментации колоректальных опухолей использованы коэффициент сходства Дайса (Dice Similarity Coefficient, DSC) и индекс пересечения над объединением (Intersection over Union, IoU). Данные метрики варьируются в диапазоне  $[0, 1]$ , где значения, близкие к 1, свидетельствуют о максимальном совпадении результатов сегментации с экспертной разметкой (Ground Truth). Математические выражения для расчета имеют следующий вид:

$$\text{Dice}(A, B) = \frac{2|A \cap B|}{|A| + |B|}$$

где  $A$  – предсказанная маска,  $B$  – эталонная маска. IoU измеряет относительную величину перекрытия двух контуров:

$$\text{IoU}(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

Динамика функции потерь и метрики Dice в процессе обучения представлена на рисунках 7 и 8. Для визуализации глобального тренда




Рисунок 7. Кривые потерь на обучении и валидации

сходимости исходные значения потерь были сглажены с помощью фильтра Савицкого-Голея (окно=5, порядок=2). Анализ кривых обучения в совокупности со статистическими данными таблица 1 показывает высокую скорость сходимости модели на первых 80 эпохах.

Итоговое значение функции потерь на обучающей выборке стабилизировалось на уровне 0.14, на валидационной – около 0.15. Плотное прилегание кривых (разрыв менее 0.05) без признаков осцилляции или роста после 80-й эпохи подтверждает высокую обобщающую способность модели и отсутствие эффекта переобучения. Значение Dice на валидационном наборе достигло стабильного плато на уровне 96% примерно к 80-й эпохе.




РИСУНОК 8. Изменение коэффициента Dice в процессе обучения

ТАБЛИЦА 1. Исходная статистика потерь (несглаженная)

Диапазон эпох	Среднее $\pm$ std обуч.	Макс/мин обуч.	Среднее $\pm$ std вал.	Макс/мин вал.
1–20	0.47 $\pm$ 0.12	0.85/0.31	0.52 $\pm$ 0.10	0.98/0.38
21–40	0.28 $\pm$ 0.06	0.37/0.19	0.31 $\pm$ 0.05	0.39/0.24
41–60	0.19 $\pm$ 0.03	0.24/0.14	0.22 $\pm$ 0.04	0.28/0.16
61–80	0.16 $\pm$ 0.02	0.18/0.11	0.17 $\pm$ 0.03	0.22/0.13
81–100	0.14 $\pm$ 0.01	0.15/0.10	0.15 $\pm$ 0.02	0.18/0.12

Кривые потерь на рисунке 7 представлены в сглаженном виде. Для обеспечения полноты описания процесса обучения в таблице 1 приведена сегментированная статистика исходных (необработанных) значений функции потерь по эпохам. Анализ первичных данных также подтверждает стабильную сходимость модели без аномальных скачков или резких флуктуаций.

Код модели доступен в открытом репозитории: <https://github.com/Wangqian33/MGA-UNet>.

### 2.3. Результаты сравнительных экспериментов

Для валидации эффективности предложенного алгоритма был проведён сравнительный анализ модели MGA-UNet с базовой архитектурой U-Net, а также современными решениями: GhostNet, Attention U-Net, U-Net++ и недавно опубликованными моделями Mamba-UNet и U-SAM. Все сопоставляемые модели обучались «с нуля» без использования предобученных весов при идентичных гиперпараметрах.

На рисунке 9 продемонстрированы результаты сегментации колоректальных опухолей. Первый столбец содержит исходные изображения,




Рисунок 9. Визуализация результатов сегментации разными моделями: каждый ряд представляет исходное изображение, U-Net, GhostNet, MGA-UNet, эталон

второй и третий – результаты U-Net и GhostNet соответственно, четвёртый – результаты предложенной модели, пятый – эталонную разметку (Ground Truth). Визуальный анализ показывает, что сеть U-Net склонна к избыточной сегментации (over-segmentation) и менее точной локализации границ. В свою очередь, MGA-UNet обеспечивает прецизионную сегментацию контуров опухоли, демонстрируя высокую степень соответствия эталону.

Количественные показатели эксперимента приведены в таблице 2. На частном наборе данных метрика Dice предложенной модели превосходит аналогичные показатели U-Net, GhostNet, Attention U-Net, U-Net++, Mamba-UNet и U-SAM на 4.45%, 1.52%, 0.87%, 0.64%, 1.32% и 0.53% соответственно. По показателю IoU прирост составил 3.93%, 1.41%, 0.79%, 0.58%, 1.08% и 0.47% соответственно. Согласно результатам парного t-теста, различие в значениях Dice между MGA-UNet и базовой U-Net

Таблица 2. Сравнение производительности различных моделей (%)

Модель	Dice	IoU	Params (M)	FLOPs (G)	Время (мс)
U-Net [9]	91.76	89.65	31.0	48.2	12.5
GhostNet [13]	94.69	92.17	8.5	12.3	5.8
Attention U-Net [26]	95.34	92.79	34.9	52.6	13.2
U-Net++ [10]	95.57	93.00	36.6	55.1	14.0
Mamba-UNet [29]	94.89	92.50	18.5	28.4	9.6
U-SAM [30]	95.68	93.11	12.4	17.8	8.4
<b>MGA-UNet</b>	<b>96.21</b>	<b>93.58</b>	<b>10.2</b>	<b>15.6</b>	<b>7.2</b>

Примечание: U-SAM (Zhang et al., 2025) – модель на основе SAM, в таблице приведены параметры только адаптера.

является статистически значимым ( $p < 0.01$ ). Все оценочные метрики подтверждают превосходство предложенного метода над современными аналогами.

Для более детального обоснования архитектурных инноваций предложенной модели в таблице 3 приведён сравнительный анализ ключевых

Таблица 3. Сравнение с близкими архитектурами

Модель	Ghost	Многомасштабность	CBAM	Вентиль внимания	Params (M)	Область
MSGU-Net [19]	✓	✓ (разные ветви)	–	✓	≈12	Кожные поражения
GA-UNet [20]	–	–	✓	✓	≈15	Опухоли печени
MGTUNet [21]	✓	Transformer	–	✓	≈25	Мульти-органная
<b>MGA-UNet</b>	✓	✓ (RFB + расшир.)	✓	✓	<b>10.2</b>	Колоректальный рак

модулей MGA-UNet в сравнении с сетями MSGU-Net, GA-UNet и MGTUNet. Как следует из сопоставления, модель MGA-UNet является единственной архитектурой, в которой одновременно интегрированы многомасштабные свёртки Ghost+RFB, бимодальный механизм внимания CBAM (канальный и пространственный) и блоки управления вниманием (Attention Gates). При этом разработанная модель обладает минимальным количеством обучаемых параметров, что подтверждает её специализацию и эффективность при обработке КТ-изображений колоректальных опухолей.

## 2.4. Абляционные эксперименты

Для оценки индивидуального вклада каждого из предложенных компонентов в общую производительность системы был проведён ряд

абляционных экспериментов. В качестве базовой линии (baseline) использовалась стандартная архитектура U-Net, к которой последовательно добавлялись: усовершенствованный свёрточный блок (Ghost+RFB), механизм внимания СВАМ и блоки управления вниманием (Attention Gate) в пропускных соединениях. Количественные результаты представлены в таблице 4.

Таблица 4. Результаты абляционных экспериментов (%)

Конфигурация	Dice	IoU
Базовый U-Net	91.76	89.65
+ улучшенный свёрточный модуль (Ghost+RFB)	93.88	91.02
+ улучшенный модуль + СВАМ	95.14	92.46
+ улучшенный модуль + СВАМ + вентили внимания (MGA-UNet)	<b>96.21</b>	<b>93.58</b>

Согласно представленным данным, каждый из интегрированных модулей внёс положительный вклад в точность сегментации. Внедрение многомасштабного свёрточного блока Ghost+RFB обеспечило прирост метрики Dice на 2,12% и IoU на 1,37%. Добавление механизма СВАМ позволило дополнительно увеличить Dice на 1,26% и IoU на 1,44%. Включение блоков Attention Gate способствовало дальнейшему росту показателей на 1,07% и 1,12% соответственно.

Результаты свидетельствуют о наличии синергетического эффекта между компонентами, при этом механизм Attention Gate оказал наиболее существенное влияние на детализацию контуров опухоли [26]. Проведённый парный t-тест подтвердил, что улучшение метрик Dice и IoU, обеспеченное каждым модулем, является статистически значимым ( $p < 0,05$ ).

## 2.5. Анализ чувствительности гиперпараметров

Для определения оптимальной конфигурации предложенной модели был проведён анализ чувствительности к весовому коэффициенту  $\beta$  в комбинированном функционале потерь. Как показано на рисунке 10, эксперименты проводились в диапазоне  $\beta \in [0, 1]$ . Результаты демонстрируют, что наивысшая производительность (Dice  $\approx 96.2\%$ ) достигается при  $\beta = 0.5$ .

При малых значениях коэффициента ( $\beta < 0.2$ ) недостаточный вклад потерь Dice затрудняет прецизионную сегментацию границ, что ведёт к снижению метрик. Напротив, при чрезмерно высоких значениях ( $\beta > 0.8$ ) заниженный вес бинарной кросс-энтропии (BCE) также вызывает умеренное снижение точности.

Дополнительно было исследовано влияние методов пула и начальной скорости обучения на эффективность модели. Установлено, что замена




РИСУНОК 10. Зависимость Dice от коэффициента ( $\beta$ )

максимального пула (Max Pooling) на усредняющий (Average Pooling) при субдискретизации приводит к снижению коэффициента Dice примерно на 0.8%. При увеличении начальной скорости обучения до  $10^{-3}$  наблюдается дестабилизация (осцилляция) процесса обучения, в результате чего значение Dice падает на 1.2%. Таким образом, в данной работе обосновано использование максимального пула с шагом 2 и скорости обучения  $10^{-4}$ .

В таблице 5 представлены результаты расширенного анализа гиперпараметров, включая коэффициент затухания весов (weight decay), вероятность Dropout и стратегии планирования скорости обучения. Эксперименты подтверждают, что при отклонении от выбранной конфигурации ( $lr=1e-4$ ,  $s=4$ ,  $WD=1e-5$ ,  $Dropout=0.5$ , косинусный отжиг) точность сегментации снижается в пределах 0.5%–1.5%. Это свидетельствует о допустимой чувствительности модели к настройкам гиперпараметров при сохранении стабильно высоких показателей в окрестности оптимума.

## Заключение

В данной работе для решения проблемы недостаточной точности существующих моделей при сегментации колоректальных опухолей предложена усовершенствованная архитектура MGA-UNet на базе U-Net. В разработанной модели стандартные свёрточные слои заменены комбинацией модулей Ghost и RFB, что позволяет сети извлекать более диверсифицированные признаки в процессе дискретизации. Интеграция механизма внимания СВМ между энкодером и декодером способствует концентрации модели на ключевых признаках, а внедрение блоков Attention Gate в пропускные соединения усиливает релевантные локальные характеристики.

Экспериментальные результаты на частном наборе КТ-данных колоректального рака показали, что предложенный метод превосходит существующие аналоги, достигая значения коэффициента Dice 96.21%. Следует отметить, что столь высокий показатель Dice получен на выборке

Таблица 5. Расширенный анализ чувствительности к гиперпараметрам (Dice %)

Гиперпараметр	Значение	Dice (%)	FLOPs (G)	Время (мс)
Скорость обучения	$10^{-5}$	94.82	15.6	7.2
	$5 \cdot 10^{-5}$	95.62	15.6	7.2
	<b><math>10^{-4}</math></b>	<b>96.21</b>	15.6	7.2
	$5 \cdot 10^{-4}$	95.35	15.6	7.2
Коэффициент сжатия $s$	2	95.67	19.2	8.5
	3	96.01	17.1	7.8
	<b>4</b>	<b>96.21</b>	15.6	7.2
	5	95.98	14.2	6.7
Вес распада	0	95.83	15.6	7.2
	<b><math>10^{-5}</math></b>	<b>96.21</b>	15.6	7.2
	$10^{-4}$	95.92	15.6	7.2
Dropout	0.0	96.24	15.6	7.2
	0.3	96.18	15.6	7.2
	<b>0.5</b>	<b>96.21</b>	15.6	7.2
	0.7	95.86	15.6	7.2
Планировщик	Фиксированный	95.44	15.6	7.2
	Ступенчатый	95.91	15.6	7.2
	<b>Косинусное затухание</b>	<b>96.21</b>	15.6	7.2

ограниченного объёма (108 пациентов) после строгой предварительной обработки (центрирование опухоли, настройка окна интенсивности), в связи с чем данные результаты могут потребовать дополнительной верификации при экстраполяции на более вариативные клинические данные.

При количестве параметров всего 10.2M и времени инференса 7.2 мс на изображение, модель перспективна для использования в сценариях клинической диагностики в реальном времени.

Направления дальнейших исследований включают:










- расширение предложенной модели до сегментации 3D КТ-объёмов [31] с разработкой 3D-версий модулей Ghost и CBAM;
- внедрение стратегий полуавтоматического обучения (semi-supervised learning) [32] для использования неразмеченных данных и повышения обобщающей способности сети;
- апробацию модели на открытых наборах данных для подтверждения её робастности.

### Благодарности

Авторы выражают благодарность сотрудникам Первой университетской больницы Хэнаньского университета науки и технологий (Первая

больница Хэнаньского университета науки и технологий, г. Лоян, Китай) за предоставленные данные.




### Список использованных источников

- [1] Bray F., Laversanne M., Sung H., Ferlay J., Siegel R. L., Soerjomataram I., Jemal A. *Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries* // CA: A Cancer Journal for Clinicians.– 2024.– Vol. **74**.– No. 3.– Pp. 229–263.  [↑170](#)
- [2] Zhao S., Wang S., Pan P., Xia T., Chang X., Yang X., Guo L., Meng Q., Yang F., Qian W., Xu Z., Wang Y., Wang Z., Gu L., Wang R., Jia F., Yao J., Li Z., Bai Y. *Magnitude, risk factors, and factors associated with adenoma miss rate of tandem colonoscopy: a systematic review and meta-analysis* // Gastroenterology.– 2019.– Vol. **156**.– No. 6.– Pp. 1661–1674.e11.  [↑170](#)
- [3] Long J., Shelhamer E., Darrell T. *Fully convolutional networks for semantic segmentation* // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (Boston, MA, USA, June 07–12, 2015).– IEEE.– 2015.– ISBN 978-1-4673-6964-0.– Pp. 3431–3440.  [arXiv:1411.4038](#) [↑170](#)
- [4] Ben-Cohen A., Diamant I., Klang E., Amitai M., Greenspan H. *Fully convolutional network for liver segmentation and lesions detection* // *International Workshop on Deep Learning in Medical Image Analysis, DLMIA 2016, LABELS 2016* (Athens, Greece, October 21, 2016), Lecture Notes in Computer Science (LNIP).– vol. **10008**, Cham: Springer.– 2016.– ISBN 978-3-319-46975-1.– Pp. 77–85.  [arXiv:1606.06650](#) [↑170](#)
- [5] Isensee F., Petersen J., Klein A., Zimmerer D., Jaeger P. F., Kohl S., Wasserthal J., Koehler G., Norajitra T., Wirkert S., Maier-Hein K. H. *nnU-Net: Self-adapting framework for U-Net-based medical image segmentation*.– 2018.– 11 pp.  [arXiv:1809.10486](#) [↑170](#)
- [6] Chen T., Son Y., Park A., Baek S.-J. *Baseline correction using a deep-learning model combining ResNet and UNet* // *Analyst*.– 2022.– Vol. **147**.– No. 19.– Pp. 4285–4292.  [↑170](#)
- [7] Chlebus G., Schenk A., Moltz J. H., Ginneken B. van, Hahn H. K., Meine H. *Automatic liver tumor segmentation in CT with fully convolutional neural networks and object-based postprocessing* // *Scientific Reports*.– 2018.– Vol. **8**.– No. 1.– id. 15497.– 7 pp.  [↑170](#)
- [8] Iqbal A., Sharif M. *UNet: A semi-supervised method for segmentation of breast tumor images using a U-shaped pyramid-dilated network* // *Expert Systems with Applications*.– 2023.– Vol. **221**.– No. 1.– id. 119718.  [URL](#) [↑171](#)
- [9] Ronneberger O., Fischer P., Brox T. *U-Net: Convolutional networks for biomedical image segmentation* // *International Conference on Medical Image Computing and Computer-Assisted Intervention*.– V. III, MICCAI (Munich, Germany, October 5–9, 2015), Lecture Notes in Computer Science (LNIP).– vol. **9351**, Cham: Springer.– 2015.– ISBN 978-3-319-24573-7.– Pp. 234–241.  [arXiv:1505.04597](#) [↑171, 183](#)
- [10] Zhou Z., Siddiquee M. M. R., Tajbakhsh N., Liang J. *UNet++: A nested U-Net architecture for medical image segmentation* // *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, DLMIA 2018, ML-CDS 2018* (Granada, Spain, September 20, 2018), Lecture Notes in Computer

- Science (LNIP).— vol. **11045**, Cham: Springer.— 2018.— ISBN 978-3-030-00888-8.— Pp. 3–11. [doi](#) [arXiv](#) 1807.10165 [↑](#)<sub>171, 183</sub>
- [11] Seo H., Huang C., Bassenne M., Xiao R., Xing L. *Modified U-Net (mU-Net) with incorporation of object-dependent high-level features for improved liver and liver-tumor segmentation in CT images* // IEEE Transactions on Medical Imaging.— 2020.— Vol. **39**.— No. 5.— Pp. 1316–1325. [doi](#) [↑](#)<sub>171</sub>
- [12] Wang Y., Lombardo E., Huang L., Belka C., Riboldi M., Kurz Ch., Landry G. *Head and neck cancer localization with Retina UNet for automated segmentation and time-to-event prognosis from PET/CT images* // *Head and Neck Tumor Segmentation and Outcome Prediction*, HECKTOR 2022 (Singapore, September 22, 2022), Lecture Notes in Computer Science.— vol. **13626**, Cham: Springer.— 2023.— ISBN 978-3-031-27419-0.— Pp. 202–211. [doi](#) [↑](#)<sub>171</sub>
- [13] Han K., Wang Y., Tian Q., Guo J., Xu Chu., Xu Cha. *GhostNet: More features from cheap operations* // *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR* (Seattle, WA, USA, June 13–19, 2020).— IEEE.— 2020.— ISBN 978-1-7281-9360-1.— Pp. 1580–1589. [doi](#) [arXiv](#) 1911.11907 [↑](#)<sub>171, 172, 174, 183</sub>
- [14] Ma N., Zhang X., Zheng H.-T., Sun J. *ShuffleNet V2: Practical guidelines for efficient CNN architecture design* // *Computer Vision — ECCV 2018*, ECCV 2018 (Munich, Germany, September 8–14, 2018), Lecture Notes in Computer Science (LNIP).— vol. **11218**, Cham: Springer.— 2018.— ISBN 978-3-030-01263-2.— Pp. 122–138. [doi](#) [%doi](#) [arXiv](#) 1807.11164 [↑](#)<sub>171</sub>
- [15] Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner Th., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. *An image is worth 16 × 16 words: Transformers for image recognition at scale* // *9th International Conference on Learning Representations, ICLR 2021* (Virtual Event, Austria, May 3–7, 2021).— 2021.— ISBN 979-8-3313-0008-1.— Pp. 611.— 21 pp. [doi](#) [arXiv](#) 2010.11929 [URL](#) [↑](#)<sub>172</sub>
- [16] Chen J., Lu Y., Yu Q., Luo X., Adeli E., Wang Y., Lu L., Yuille A. L., Zhou Y. *TransUNet: Transformers make strong encoders for medical image segmentation*.— 2021.— 13 pp. [doi](#) [arXiv](#) 2102.04306 [↑](#)<sub>172</sub>
- [17] Hatamizadeh A., Tang Y., Nath V., Yang D., Myronenko A., Landman B., Roth H., Xu D. *UNETR: Transformers for 3D medical image segmentation* // *2022 IEEE/CVF Winter Conference on Applications of Computer Vision, WACV* (Waikoloa, HI, USA, January 03–08, 2022).— IEEE.— 2022.— ISBN 978-1-6654-0916-2.— Pp. 1748–1758. [doi](#) [arXiv](#) 2103.10504 [↑](#)<sub>172</sub>
- [18] Сухов П. А., Данилюк С. С. *Применение трансформеров для сегментации медицинских изображений* // *Вестник науки*.— 2024.— Т. **1**.— № 6 (75).— С. 1539–1546.— ид. 230. [\\*](#) [URL](#) [↑](#)<sub>172</sub>
- [19] Cheng H., Zhang Y., Xu H., Li D., Zhong Z., Zhao Y., Yan Zh. *MSGU-Net: A lightweight multi-scale ghost U-Net for image segmentation* // *Frontiers in Neurorobotics*.— 2025.— Vol. **18**.— id. 1480055. [doi](#) [↑](#)<sub>172, 183</sub>
- [20] Pang B., Chen L., Tao Q., Wang E., Yu Y. *GA-UNet: A lightweight ghost and attention U-Net for medical image segmentation* // *Journal of Imaging Informatics in Medicine*.— 2024.— Vol. **37**.— No. 4.— Pp. 1874–1888. [doi](#) [↑](#)<sub>172, 183</sub>

- [21] Pan L., Wang L., Feng Zh., Xu Zh., Xu L., Peng Sh. *MGTUNet: A new UNet for colon nuclei instance segmentation and quantification.*– 2022.– 5 pp. [doi](#) [arXiv](#) 2210.10981 [↑](#)<sub>172, 183</sub>
- [22] Liu S., Huang D., Wang Y. *Receptive field block net for accurate and fast object detection // Computer Vision — ECCV 2018.*– V. XI, ECCV 2018 (Munich, Germany, September 8–14, 2018), Lecture Notes in Computer Science (LNIP).– vol. **11215.**– 2018.– ISBN 978-3-030-01251-9.– Pp. 404–419. [doi](#) [arXiv](#) 1711.07767 [↑](#)<sub>173</sub>
- [23] Chen L. C., Papandreou G., Kokkinos I., Murphy K., Yuille A. L. *DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs // IEEE Transactions on Pattern Analysis and Machine Intelligence.*– 2018.– Vol. **40.**– No. 4.– Pp. 834–848. [doi](#) [arXiv](#) 1606.00915 [↑](#)<sub>174</sub>
- [24] He K., Zhang X., Ren S., Sun J. *Deep residual learning for image recognition // Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR (Las Vegas, NV, USA, June 27–30, 2016).*– IEEE.– 2016.– ISBN 978-1-4673-8851-1.– Pp. 770–778. [doi](#) [%doi](#) [arXiv](#) 1512.03385 [↑](#)<sub>175</sub>
- [25] Woo S., Park J., Lee J.-Y., Kweon I.-S. *CBAM: Convolutional block attention module // Computer Vision — ECCV 2018, ECCV 2018 (Munich, Germany, September 8–14, 2018), Lecture Notes in Computer Science (LNIP).*– vol. **11211,** Cham: Springer.– 2018.– ISBN 978-3-030-01233-5.– Pp. 3–19. [doi](#) [%doi](#) [arXiv](#) 1807.06521 [↑](#)<sub>175</sub>
- [26] Oktay O., Schlemper J., Folgoc L. L., Lee M., Heinrich M., Misawa K., Mori K., McDonagh S., Hammerla N. Y., Kainz B., Glocker B., Rueckert D. *Attention U-Net: Learning where to look for the pancreas.*– 2018.– 10 pp. [doi](#) [arXiv](#) 1804.03999 [↑](#)<sub>176, 183, 184</sub>
- [27] Fei G., Yan B., Chen J., Qiao K., Ning P., Shi D. *Liver tumor segmentation based on dilated convolution of stacked tree aggregation structure // Acta Optica Sinica.*– 2021.– Vol. **41.**– No. 18.– id. 1810002. [doi](#) [URL](#) [↑](#)<sub>178</sub>
- [28] Paszke A., Gross S., Massa F., Lerer A., Bradbury J., Chanan G., Killeen T., Lin Z., Gimelshein N., Antiga L., Desmaison A., Köpf A., Yang E. Z., DeVito Z., Raison M., Tejani A., Chilamkurthy S., Steiner B., Fang L., Bai J., Chintala S. *PyTorch: An imperative style, high-performance deep learning library // Advances in Neural Information Processing Systems 32: Annual Conference on Neural Information Processing Systems 2019, NeurIPS 2019 (Vancouver, BC, Canada, December 8–14, 2019).*– 2019.– ISBN 9781713807933.– Pp. 8024–8035. [arXiv](#) 1912.01703 [doi](#) [URL](#) [↑](#)<sub>179</sub>
- [29] Wang Z., Zheng J. Q., Zhang Y., Cui G., Li L. *Mamba-UNet: UNet-like pure visual Mamba for medical image segmentation.*– 2024.– 12 pp. [doi](#) [arXiv](#) 2402.05079 [↑](#)<sub>183</sub>
- [30] Zhang H., Guo W., Wan Sh., Zou B., Wang W., Qiu C., Liu K., Jin P., Yang J. *Tuning vision foundation models for rectal cancer segmentation from CT scans // Communications Medicine.*– 2025.– Vol. **5.**– No. 1.– id. 256.– 11 pp. [doi](#) [↑](#)<sub>183</sub>
- [31] Çiçek Ö., Abdulkadir A., Lienkamp S. S., Brox T., Ronneberger O. *3D U-Net: Learning dense volumetric segmentation from sparse annotation // International Conference on Medical Image Computing and Computer-Assisted Intervention.*– V. II, MICCAI 2016 (Athens, Greece, October 17–21, 2016), Lecture Notes

in Computer Science (LNIP).— vol. **9901**, Cham: Springer.— 2016.— ISBN 978-3-319-46722-1.— Pp. 424–432.   arXiv  1606.06650  186


- [32] Zhou Y., Wang Y., Tang P., Bai S., Shen W., Fishman E. K., Yuille A. L. *Semi-supervised 3D abdominal multi-organ segmentation via deep multi-planar co-training // 2019 IEEE Winter Conference on Applications of Computer Vision, WACV (Waikoloa, HI, USA, January 07–11, 2019).*— IEEE.— 2019.— ISBN 978-1-7281-1975-5.— Pp. 121–140.  arXiv  1804.02586  186

Поступила в редакцию 19.04.2026;  
одобрена после рецензирования 28.04.2026;  
принята к публикации 29.05.2026;  
опубликована онлайн 20.06.2026.

Рекомендовал к публикации


*к.ф.-м.н. А. Н. Виноградов*

## Информация об авторах:



Юйцян Ван

Аспирант Томского политехнического университета (ТПУ).  
Область научных интересов: системный анализ, управление и обработка информации, статистика, медицинская информатика, глубокое обучение, сегментация изображений

 0000-0003-3755-0586  
**e-mail:** [wanguyqian3333@gmail.com](mailto:wanguyqian3333@gmail.com)



Сергей Владимирович Аксёнов

Доцент отделения информационных технологий (ИШИТР) Томского политехнического университета, кандидат технических наук. Научные интересы связаны с системным анализом, управлением и обработкой информации, программными системами и медицинской информатикой

 0000-0002-1251-7133  
**e-mail:** [axyonov@tpu.ru](mailto:axyonov@tpu.ru)

*Авторы внесли равный вклад в подготовку публикации.*

*Декларация об отсутствии личной заинтересованности: благополучие авторов не зависит от результатов исследования.*