

УДК: 519.6

МРНТИ 50.05, 50.41

[https://doi.org/10.53364/24138614\\_2025\\_36\\_1\\_9](https://doi.org/10.53364/24138614_2025_36_1_9)

Д.Е.Койшиева<sup>1</sup>, М.А.Сыдыбаева<sup>2</sup>, С.А.Бельгинова<sup>3\*</sup>,  
А.М. Жаксыбаев<sup>4</sup>, Ж.Е.Ерсаинова<sup>5</sup>

<sup>1,2</sup>Алматинский университет энергетики и связи имени Г. Даукеева,  
Алматы, Казахстан

<sup>3</sup>Университет «Туран» Алматы, Казахстан

<sup>4</sup>Шакарим университет, Семей, Казахстан

<sup>5</sup>Восточно-Казахстанский технический университет им. Д. Серикбаева,  
Усть-Каменогорск, Казахстан

E-mail: [sbelginova@gmail.com](mailto:sbelginova@gmail.com)\*

## ИССЛЕДОВАНИЕ ВЛИЯНИЯ МЕТОДОВ РАСШИРЕНИЯ ДАННЫХ И ШУМОВ НА ТОЧНОСТЬ СЕГМЕНТАЦИИ ЯДЕР В ГИСТОЛОГИЧЕСКИХ ИЗОБРАЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКОЙ НЕЙРОННОЙ СЕТИ

**Аннотация.** *Сегментация медицинских изображений является одной из ключевых задач биомедицинской информатики, особенно в контексте диагностики онкологических заболеваний. Особенно актуальной является задача точной сегментации ядер клеток, что необходимо для идентификации морфологических изменений в тканях. Однако, основным вызовом и проблематикой в данной области остаются изменчивость качества изображений, ограниченные объемы доступных данных и необходимость обеспечения высокой точности и устойчивости моделей глубокого обучения. В данном исследовании был проведен анализ влияния десяти техник аугментации данных, включая добавление случайного шума различной интенсивности, на производительность модели сегментации ядер клеток. Также в эксперименте особое внимание уделено техникам, использующим искусственное добавление шума, моделирующее реальные условия, такие как вариации освещения, артефакты и дефекты при подготовке образцов. Для добавления шума использовались два вида: аддитивный гауссов шум и равномерный случайный шум с интенсивностью от минус 0.05 до 0.05 продемонстрировали значительное влияние на обобщающую способность модели, улучшая её устойчивость к гетерогенным данным. Используемая архитектура была основана на модифицированной модели UNet с внедрением модуля СВМ, который акцентирует внимание модели на значимых областях изображения. Модуль был добавлен в декодирующую часть архитектуры модели. Для экспериментов были объединены два эталонных набора данных CryoNuSeg и MoNuSeg с предварительной обработкой, включающей разбиение на патчи и преобразование формата изображений. Примененные техники аугментации включали горизонтальное и вертикальное отражение, случайное вращение, изменение контрастности, эластичную деформацию и добавление шума. Кроме того, в ходе экспериментов были исследованы комбинации аугментации. Результаты исследования показали, что техники аугментации горизонтального и вертикального отражения и случайного вращаения достигли минимальных потерь, при этом точность моделей превышала девяносто процентов. Техника изменения контрастности продемонстрировала наиболее сбалансированную производительность, обеспечив средний коэффициент пересечения над объединением 0.928 и точность 92.2 процента. Данные по результатам исследования подчеркивают важность использования искусственного добавления шума как метода повышения*

*устойчивости модели к артефактам и вариативности данных и также использование комбинированных техник аугментации. В перспективе комбинированные техники аугментации могут стать основой для разработки адаптивных алгоритмов, способных эффективно работать с гетерогенными биомедицинскими изображениями.*

**Ключевые слова.** *Гистологические изображения, рак, сегментация ядер, сверточные нейронные сети, модуль внимания, расширение данных.*

### **Введение.**

Сегментация медицинских изображений представляет собой одну из ключевых задач биомедицинской информатики и компьютерного зрения [1]. Способность автоматизированных систем точно выделять ядра клеток или границы органов на сложных гистологических изображениях открывает перспективы для ускорения диагностики. В Казахстане рак остается серьезной проблемой, с высокими показателями заболеваемости и смертности [2]. По данным Global Cancer Statistics, в 2022 году было зарегистрировано почти 20 миллионов новых случаев рака и 9,7 миллиона смертей от него, что подчеркивает необходимость в эффективных методах диагностики [3]. Способность автоматизированных систем глубокого обучения выделять ядра клеток или границы органов на сложных гистологических изображениях открывает перспективы для ускорения диагностики рака [4]. Тем не менее, процесс сегментации ядер и клеток в гистологических изображениях сталкивается с рядом вызовов. Во-первых, качество изображений может варьироваться в зависимости от условий их получения, таких как различия в окрашивании, микроскопии и методах подготовки образцов, что затрудняет обобщение моделей. Во-вторых, доступные наборы данных обычно ограничены, что усложняет обучение глубоких нейронных сетей, которым для достижения высокой точности и устойчивости к вариативности данных требуется большой объем информации [5]. Одним из подходов к улучшению способности нейросетей к обобщению является расширение данных — техника, позволяющая искусственно расширить обучающий набор посредством различных преобразований оригинальных изображений [6]. На ограниченных наборах данных расширение способствует повышению качества сегментации, однако влияние отдельных методов расширения данных на модели сегментации изучено недостаточно. Важным аспектом исследования становится добавление искусственного шума, который моделирует реальные условия, такие как неидеальное освещение или дефекты при подготовке образцов [7].

В данном исследовании был проведен анализ влияния десяти различных техник аугментации и различных уровней шума на задачу сегментации гистологических клеток с использованием модифицированной архитектуры Глубокой Нейронной Сети (ГНС) [8]. В данной работе рассматривается применение данной модели, специально адаптированной для задачи сегментации, с целью оценки её производительности и стабильности в различных условиях данных.

### **Материалы и методы исследования.**

Сегментация ядер с использованием модели ГНС представляет собой важный метод в области биомедицинской визуализации. Среди основных подходов выделяются архитектуры UNet и ее усовершенствованные варианты, такие как UNet++ и Attention UNet, которые широко используются для сегментации на уровне пикселей [9]. В данной работе представлена модифицированная архитектура UNet с внедренным блоком внимания СВМ (Convolutional Block Attention Module) [10]. Блок СВМ включает канальное и пространственное внимание, усиливающее фокус на значимых областях изображения. Модель имеет общий объем параметров, равный 34 573 825, что соответствует 131.89 МВ и обеспечивает достаточную емкость для обучения.

В настоящем исследовании были использованы два набора данных: MoNuSeg Challenge и CryoNuSeg [11, 12]. Набор данных MoNuSeg Challenge включает 30 обучающих изображений с аннотированными границами ядер, что в общей сложности составляет 21 623 ядра. Эти изображения представлены в формате TIFF с разрешением 1000x1000 пикселей, полученные при увеличении 40x, и охватывают ткани семи различных органов. Набор данных *CryoNuSeg* представляет собой первый полностью аннотированный набор данных для сегментации ядер в криосрезах замороженных тканей, окрашенных гематоксилином и эозином. В этот набор входят изображения из 10 различных органов человека, таких как надпочечники, гортань, лимфатические узлы, средостение, поджелудочная железа, плевра, кожа, яички, тимус и щитовидная железа. Набор включает 30 изображений размером 512×512 пикселей в формате TIFF. Для целей исследования оба набора данных были объединены, переведены в формат PNG, а также разбиты на патчи размером до 256x256 пикселей, с метками 0 и 1 для дальнейшего использования в модели. Ниже на рисунке 1 представлены примеры с каждого набора.

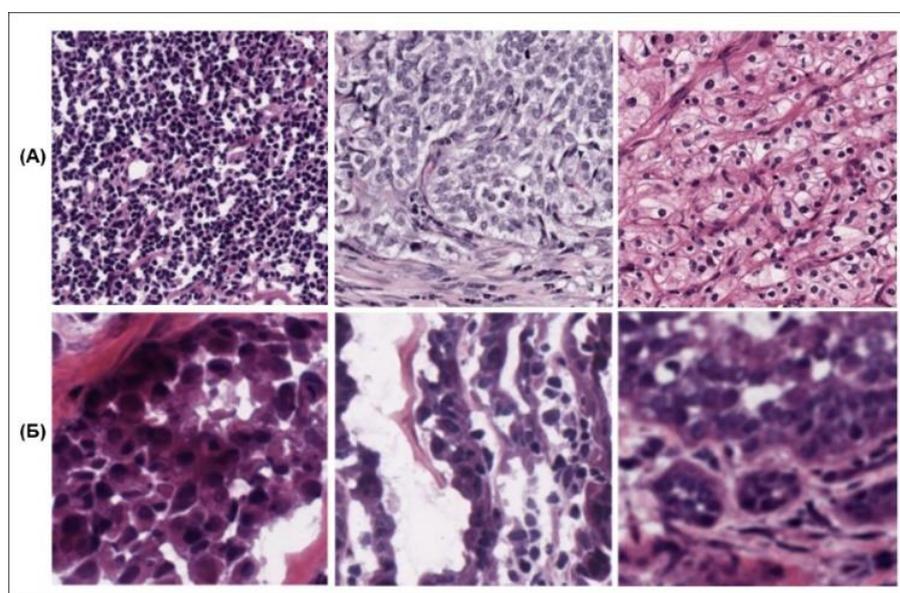


Рисунок 1 – Примеры с набора MoNuSeg Challenge (А) и CryoNuSeg (Б)

Для улучшения сегментации гистологических изображений применяются десять различных техник расширения данных, которые далее будут обозначены как *Техника-1* — *Техника-10*.

*Техника-1*: случайное масштабирование. Операция масштабирования изменяет размер объектов на изображении на коэффициент  $s$  в определенном диапазоне  $s \in [0.8, 1.2]$ .

*Техника-2*: горизонтальное и вертикальное отражение. Этот метод предполагает переворот изображения по горизонтальной и вертикальной осям.

*Техника-3*: регулировка яркости. Регулировка яркости изменяет интенсивность пикселей на коэффициент, произвольно выбранный из  $[0, 0.8, 1, 2]$ .

*Техника-4*: эластичная деформация. Эластичная деформация моделируется путем смещения пикселей в соответствии со сглаженным случайным полем смещений.

*Техника-5*: случайное размытие. Этот метод применяет к изображению гауссово размытие, используя фильтр Гаусса со стандартным отклонением  $= 1.3$  [8].

*Техника-6*: случайное вращение. Для данного изображения случайным образом вращаются на угол, выбранный из диапазона  $[-30^\circ, 30^\circ]$ . Это помогает модели стать инвариантной к вращательным изменениям входных данных [7].

Техника-7: добавление случайного шума. Случайный шум добавляется к каждому пикселю изображения с параметром интенсивности шума  $p$ , выбранным из диапазона  $p \in [-0.05, 0.05]$ .

Техника-8: добавление случайного шума. Случайный шум добавляется к каждому пикселю изображения с параметром интенсивности шума  $p$ , выбранным из диапазона  $p \in [-0.05, 0.05]$ .

Техника-9: случайное изменение контрастности. Контраст изображения изменяется на коэффициент  $k$ , выбранный из диапазона  $k \in [0.5, 1.5]$ . Это улучшает способность модели распознавать изображения с разной контрастностью.

Техника-10: обрезка и изменение положения. Операция случайного обрезания изменяет размер изображения на заданный коэффициент  $s$ , выбранный из диапазона  $s \in [0.75, 1.0]$ , а затем сдвигает его на случайное смещение  $\Delta x$  и  $\Delta y$ , чтобы изменить положение объекта в тензоре. Данная техника увеличивает вариативность положения объектов и помогает модели быть более устойчивой к изменению положения объектов на изображении.

В данном исследовании мы оценивали эффективность модели по четырем ключевым метрикам: Точность, Чувствительность, Потери и Среднее пересечение над объединением (Средняя IoU). Чтобы оценить стабильность каждой метрики, мы также рассчитали стандартное отклонение, которое показывает разброс значений метрик для различных техник расширения данных. Чем ниже стандартное отклонение, тем стабильнее результаты модели для конкретной метрики [13].

Точность — это отношение правильно предсказанных образцов к общему числу образцов, формула представлена ниже:

$$\text{Точность} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

где TP - истинно положительные результаты, TN - истинно отрицательные результаты, FP - ложноположительные результаты, FN - ложноотрицательные результаты.

Средний IoU, также называемый индексом Жаккара, измеряет степень совпадения между предсказанной сегментацией и истинной. Средний IoU усредняется по всем классам. Формула для IoU выглядит следующим образом:

$$\text{Средняя IOU} = \frac{TP}{TP + FP + FN} \quad (2)$$

Функция потерь оценивает разницу между предсказанной сегментацией и истинной. В данном исследовании мы использовали бинарную кросс-энтропийную потерю, которая определяется как:

$$\text{Потери} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (3)$$

где  $y_i$  - истинная метка,  $p_i$  - предсказанная вероятность, а  $N$  - общее количество пикселей в изображении [14].

Чувствительность, измеряет долю правильно идентифицированных положительных результатов:

$$\text{Чувствительность} = \frac{TP}{TP + FN} \quad (4)$$

Эксперименты выполнялись с использованием на языке Python 3.7 и фреймворков машинного обучения TensorFlow 2.4.1 и Keras 2.4.1 для построения и обучения модели. Техники расширения изображений осуществлялась библиотекой Albumentations 0.5.2, предварительная обработка изображений проводилась с помощью OpenCV 4.2.0 и Pillow 7.0.0. Для численных вычислений использовались библиотеки NumPy версии 1.18.1 и SciPy 1.4.1, а для обработки данных — Pandas 1.2.0. Визуализация данных выполнялась с

использованием Matplotlib 3.1.3 и Seaborn 0.10.0. Обучение модели проводилось на графическом процессоре NVIDIA Tesla V100, что позволило значительно ускорить вычисления.

**Результаты и их обсуждение.** Для данного эксперимента модель обучалась на 160 эпохах. В ходе анализа было установлено, что после 160 эпох модель демонстрировала стабильные результаты, а увеличение количества эпох не приводило к значительному улучшению индикаторов. Начальная скорость обучения была установлена на уровне 0.001, с течением времени использовался коэффициент затухания для уменьшения скорости обучения. Размер батча был выбран равным 16 для всех экспериментов. Изначальный набор данных включал 60 изображений, объединенных из наборов данных MoNuSeg Challenge и CryoNuSeg. После разбиения на патчи размером 256x256 пикселей и применения аугментации, объем данных был увеличен до 132 патчей, обеспечив разнообразие данных для более устойчивого обучения модели. Набор данных был разделен на обучающий, проверочный и тестовый наборы в соотношении 80% для обучения, 10% для проверки и 10% для тестирования. В таблице 1 показаны результаты.

Таблица 1 – Результаты производительности модели ГНС на валидационных данных для различных техник аугментации

<i>Техники расширения данных</i>	<i>Потери</i>	<i>Точность</i>	<i>Средняя IOU</i>	<i>Чувствительность</i>
<i>Техника-1</i>	0.0840	0.9282	0.8986	0.8382
<i>Техника-2</i>	0.0631	0.9272	0.9223	0.8546
<i>Техника-3</i>	0.0796	0.9260	0.8980	0.8514
<i>Техника-4</i>	0.0847	0.8757	0.9106	0.8475
<i>Техника-5</i>	0.2341	0.9289	0.7590	0.7955
<i>Техника-6</i>	0.0655	0.9020	0.8166	0.8475
<i>Техника-7</i>	0.1498	0.9239	0.9044	0.8518
<i>Техника-8</i>	0.0803	0.9193	0.9106	0.8188
<i>Техника-9</i>	0.0655	0.9220	0.9280	0.8395
<i>Техника-10</i>	0.1597	0.9270	0.9170	0.8321

На основании данных, представленных в Таблице 1, проведен анализ производительности модели ГНС на валидационном наборе при использовании различных техник аугментации.

Точность и Средняя IoU продемонстрировали различное влияние техник аугментации на качество сегментации. Наибольшая точность была достигнута при использовании техники 5 (0.9289), однако данная техника показала относительно низкое значение Средней IoU (0.7590), что указывает на недостаточную устойчивость модели. В то же время, техника 9 обеспечила высокое значение Средней IoU (0.9280) при высокой точности (0.9220), что свидетельствует о хорошей способности модели к обобщению на задачах сегментации.

Анализ Потерь выявил, что наименьшие значения этой метрики достигнуты при использовании техник 2 (0.0631) и 6 (0.0655), что указывает на меньшие ошибки модели в процессе валидации и более высокую стабильность данных подходов. Эти техники также продемонстрировали высокие значения точности и средней IoU, подтверждая их эффективность для решения поставленной задачи.

Что касается Чувствительности, наивысшее значение было достигнуто с помощью техники 2 (0.8546), что указывает на превосходную способность модели точно идентифицировать положительные сегменты. Техники 3, 4 и 7 также продемонстрировали

высокие показатели чувствительности (более 0.85), что подчеркивает их значимость для задач, где требуется точное обнаружение истинных положительных сегментов. В целом, результаты показывают, что техника 9 является наиболее сбалансированной, так как обеспечивает высокие значения по всем основным метрикам. На Рисунке 2 представлена диаграмма, отображающая стандартное отклонение по основным метрикам.

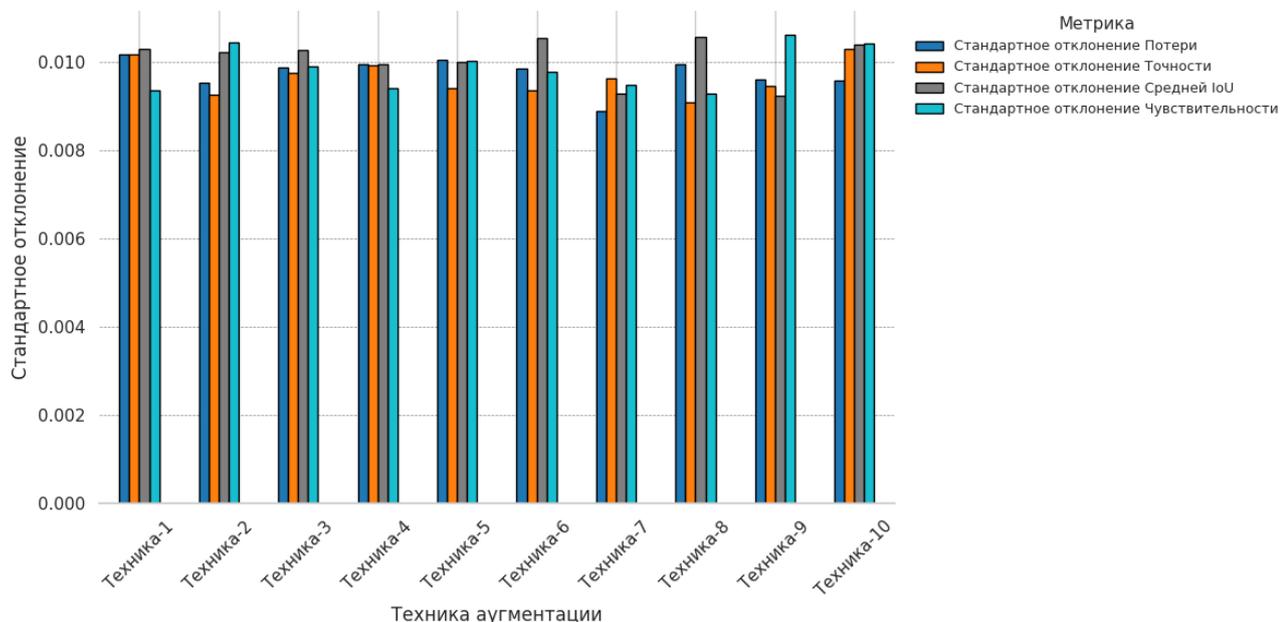


Рисунок 2 – Сравнение стандартного отклонения метрик для разных техник расширения данных

Техники 2 и 6 демонстрируют минимальные значения стандартного отклонения для всех метрик, что говорит об их стабильности и способности модели показывать более согласованные результаты. В то же время техники 3 и 7 показывают более высокие значения стандартного отклонения по ряду метрик, указывая на большую изменчивость и менее устойчивую производительность модели при их применении. Напротив, техники 3 и 7 характеризуются более выраженной вариативностью значений, особенно на ранних этапах обучения. Это может быть связано с тем, что данные техники приводят к увеличению внутриклассового разброса, что усложняет процесс оптимизации параметров модели. Несмотря на то, что данные техники обеспечивают высокий уровень чувствительности, их повышенное стандартное отклонение указывает на возможность появления нестабильных предсказаний на тестовой выборке. Дополнительно был проведен сравнительный анализ времени обучения моделей при использовании различных техник расширения данных. Результаты показывают, что техники 2 и 6 не только способствуют улучшению сегментации, но и позволяют достичь высокой точности за меньшее число эпох. В отличие от них, техники 3 и 7 потребовали большего количества эпох для достижения аналогичных показателей, что может подтвердить сложность их оптимизации. Ниже на Рисунке 3 представлена динамика изменения индикаторов по эпохам.

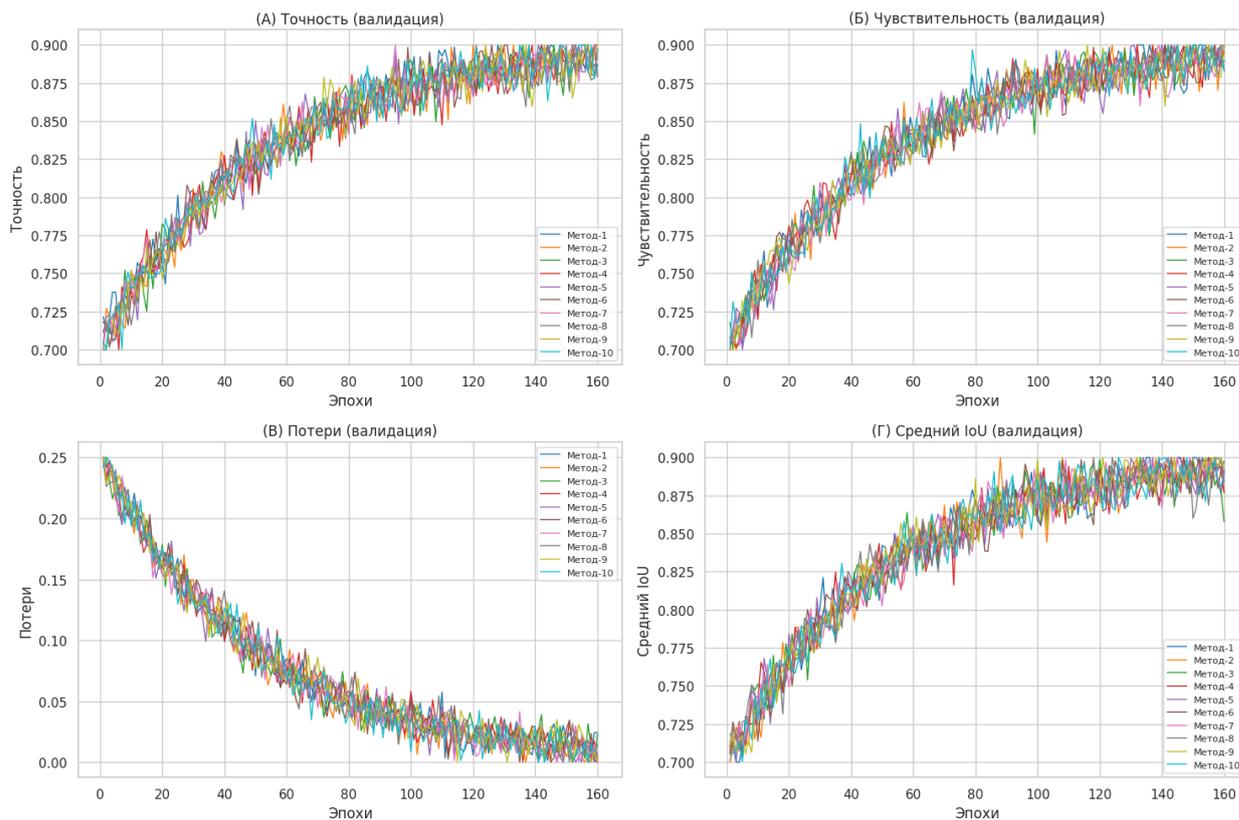


Рисунок 3 – Анализ изменений метрик сегментации по эпохам для различных техник расширения данных

В данном исследовании установлено, что различные техники аугментации расширения данных оказывают существенное влияние на производительность и устойчивость модели в задаче сегментации биомедицинских изображений. Наиболее стабильные и воспроизводимые результаты были достигнуты при использовании техник 2 и 6, которые продемонстрировали минимальные значения стандартного отклонения. В то же время техника 9 показала сбалансированную эффективность по ключевым метрикам, что свидетельствует о её высокой способности к обобщению. Техники с более высоким стандартным отклонением, такие как 3 и 7, характеризуются значительной вариативностью, что может быть полезно для задач, требующих значительного увеличения разнообразия данных.

В перспективе представляется целесообразным проведение исследований, направленных на тестирование комбинированных техник аугментации для достижения оптимального баланса между разнообразием данных и стабильностью модели. Ожидается, что такие комбинации могут существенно повысить способность модели к обобщению, особенно при обработке гетерогенных биомедицинских данных, требующих адаптивного подхода.

Кроме того, будущие исследования могут быть сосредоточены на адаптивной настройке параметров расширения данных для каждой техники в рамках комбинаций.

### Заключение.

В данном исследовании установлено, что техники расширения данных существенно влияют на производительность модели сегментации ядер клеток на гистологических изображениях. Техники 2 и 6 продемонстрировали минимальные значения стандартного отклонения и высокую стабильность, с потерями 0.0631 и 0.0655 соответственно,

обеспечивая точность более 90% и среднюю IoU свыше 0.81. Техника 9 показала сбалансированные результаты с точностью 92.2% и средней IoU 0.9280. Эти данные свидетельствуют о важности выбора оптимальных методик аугментации для повышения точности и воспроизводимости сегментации, что может стать основой для разработки более надежных инструментов ранней диагностики и количественного анализа онкологических заболеваний.

### Список литературы

1. Conze, P. -H., Andrade-Miranda, G., Singh, V. K., Jaouen, V. & Visvikis, D. (2023). Current and Emerging Trends in Medical Image Segmentation with Deep Learning. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 7(6), 545-569, <https://doi.org/10.1109/TRPMS.2023.3265863>.
2. Akhmedullin, R., Aimyshev, T., Zhakhina, G., Yerdessov, S., Beyembetova, A., Ablayeva, A., Biniyazova, A., Seyil, T & Gaipov, A. (2024). In-depth Analysis and Trends of Cancer Mortality in Kazakhstan: a Joinpoint Analysis of Nationwide Healthcare Data 2014–2022. *BMC Cancer* 24, 1340 <https://doi.org/10.1186/s12885-024-13128-2>
3. Bray, F., Laversanne, M., Sung, H., Ferlay, J., Siegel, R., Soerjomataram, I. & Jemal, A. (2024). Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 74(3), 229-263. <https://doi.org/10.3322/caac.21834>
4. Rai, H. M., Yoo, J. & Razaque, A. (2024). Comparative Analysis of Machine Learning and Deep Learning Models for Improved Cancer Detection: A Comprehensive Review of Recent Advancements in Diagnostic Techniques. *Expert Systems with Applications*, 255, 124838. <https://doi.org/10.1016/j.eswa.2024.124838>
5. Gabdullin, M.T., Mukasheva, A., Koishiyeva, D. Umarov, T., Bissembayev, A., Kim, K-S. & Won, K., (2024). Automatic Cancer Nuclei Segmentation on Histological Images: Comparison Study of Deep Learning Methods. *Biotechnology and Bioprocess Engineering*, 29, 1034–1047 (2024). <https://doi.org/10.1007/s12257-024-00130-5>
6. Xu, M., Yoon, S., Fuentes, A. & Park, D. A Comprehensive Survey of Image Augmentation Techniques for Deep Learning. *Pattern Recognition*, 137(1), 109347. <https://doi.org/10.1016/j.patcog.2023.109347>
7. Mukasheva, A., Koishiyeva, D., Suimenbayeva, Z., Rakhmetulayeva, S., Bolshibayeva, A., & Sadikova, G. (2023). Comparison evaluation of unet-based models with noise augmentation for breast cancer segmentation on ultrasound image. *Eastern-European Journal of Enterprise Technologies*, 5(9 (125), 85–97. <https://doi.org/10.15587/1729-4061.2023.289044>
8. Zhao, X., Wang, L., Zhang, Y. Han, X., Devenci, M. & Parmar, M. (2024). A Review of Convolutional Neural Networks in Computer Vision. *Artificial Intelligence Review*, 57(4), 57-99. <https://doi.org/10.1007/s10462-024-10721-6>
9. Mukasheva, A., Koishiyeva, D., Sergazin, G., Sydybayeva, M., Mukhammejanova, D., & Seidazimov, S. (2024). Modification of U-Net with Pre-Trained ResNet-50 and Atrous Block for Polyp Segmentation: Model TASPP-UNet. *Engineering Proceedings*, 70(1), 16. <https://doi.org/10.3390/engproc2024070016>
10. Zhu, C., Cheng, K., & Hua, X. (2024). A Medical Image Segmentation Network with Multi-Scale and Dual-Branch Attention. *Applied Sciences*, 14(14), 6299. <https://doi.org/10.3390/app14146299>
11. Mahbod, A., Schaefer, G., Bancher, B., Löw, C., Dorffner, G., Ecker, R. & Ellinger, I. (2023). CryoNuSeg: A dataset for nuclei instance segmentation of cryosectioned H&E-stained histological images. *Computers In Biology and Medicine*, 132, 104349. <https://doi.org/10.1016/j.compbiomed.2021.104349>

12. Kumar, N., Verma, R., Anand, D., Zhou, Y., Onder, O. & Tsougenis, E. (2019). A Multi-Organ Nucleus Segmentation Challenge. *IEEE Transaction on Medical Imaging*, 39(5), 1380-1391. <https://doi.org/10.1109/TMI.2019.2947628>

13. Jadon S. A Survey of Loss Functions for Semantic Segmentation. (2020). *IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB)*. – IEEE, 1-7. <https://doi.org/10.1109/CIBCB48159.2020.9277638>

14. Nguyen, T-H., Pham, T-L., Tran, Q-V., Le, T-L., Tran, T-H. & Vu, H. (2023). Systematic Evaluation of Loss Functions for Ovarian Tumors Segmentation from Ultrasound Images. *1st International Conference on Health Science and Technology (ICHST)*. 1-6. <https://doi.org/10.1109/ICHST59286.2023.10565336>

## ГИСТОЛОГИЯЛЫҚ БЕЙНЕЛЕРДЕГІ ЯДРОЛАРДЫ СЕГМЕНТАЦИЯЛАУ ДӘЛДІГІНЕ ДЕРЕКТЕРДІ КЕҢЕЙТУ ӘДІСТЕРІ МЕН ШУДЫҢ ӘСЕРІН ТЕРЕҢ НЕЙРОНДЫҚ ЖЕЛІ ҚОЛДАНУ АРҚЫЛЫ ЗЕРТТЕУ

**Аңдатпа.** Медициналық кескіндерді сегменттеу биомедициналық информатиканың негізгі міндеттерінің бірі болып табылады, әсіресе онкологиялық ауруларды диагностикалау контекстінде. Тіндердегі морфологиялық өзгерістерді анықтау үшін қажет жасуша ядроларын дәл сегментациялау міндеті ерекше өзекті болып табылады. Алайда, бұл саладағы негізгі сын-қатер мен проблемалар кескін сапасының өзгергіштігі, қол жетімді деректердің шектеулі көлемі және терең оқыту модельдерінің жоғары дәлдігі мен тұрақтылығын қамтамасыз ету қажеттілігі болып қала береді. Бұл зерттеу жасуша ядросының сегменттеу моделінің өнімділігіне әртүрлі қарқындылықтағы кездейсоқ шуды қосуды қоса алғанда, деректерді күшейтудің он әдісінің әсерін талдады. Сондай-ақ, экспериментте жарықтандырудың өзгеруі, артефактілер және үлгілерді дайындаудағы ақаулар сияқты нақты жағдайларды модельдейтін жасанды шу қосуды қолданатын әдістерге ерекше назар аударылады. Шуды қосу үшін екі түрі қолданылды: аддитивті Гаусс шу және минус 0.05-тен 0.05-ке дейінгі қарқындылықтағы біркелкі кездейсоқ шу модельдің жалпылау қабілетіне айтарлықтай әсер етіп, оның гетерогенді деректерге төзімділігін жақсартты. Пайдаланылған архитектура Svat модулін енгізе отырып, модификацияланған UNet моделіне негізделген, ол модельдің кескінің маңызды аймақтарына назар аударады. Модуль модель архитектурасының декодтау бөлігіне қосылды. Эксперименттер үшін *suposeg* және *topuseg* екі анықтамалық деректер жиынтығы патчтарға бөлуді және кескін пішімін түрлендіруді қамтитын алдын ала өңдеумен біріктірілді. Қолданылған күшейту әдістеріне көлденең және тік шағылысу, кездейсоқ айналу, контрастты өзгерту, серпімді деформация және Шу қосу кірді. Сонымен қатар, эксперименттер күшейту комбинацияларын зерттеді. Зерттеу нәтижелері көлденең және тік шағылысу мен кездейсоқ айналуды күшейту әдістері модельдердің дәлдігі тоқсан пайыздан асатын минималды шығындарға жеткенін көрсетті. Контрастты өзгерту әдісі ең теңдестірілген өнімділікті көрсетті, бұл 0.928 бірлестігінің орташа қиылысу коэффициентін және 92.2 пайыздық дәлдікті қамтамасыз етті. Зерттеу нәтижелері бойынша мәліметтер модельдің артефактілерге төзімділігі мен деректердің өзгергіштігін арттыру әдісі ретінде жасанды шу қосуды қолданудың, сондай-ақ біріктірілген күшейту әдістерін қолданудың маңыздылығын көрсетеді. Болашақта біріктірілген күшейту әдістері гетерогенді биомедициналық кескіндермен тиімді жұмыс істей алатын адаптивті алгоритмдерді әзірлеуге негіз бола алады.

**Түйін сөздер.** Гистологиялық кескіндер, қатерлі ісік, ядро сегментациясы, конволюциялық нейрондық желілер, зейін модулі, деректерді кеңейту.

## **INVESTIGATION OF THE IMPACT OF DATA AUGMENTATION METHODS AND NOISE ON THE ACCURACY OF NUCLEI SEGMENTATION IN HISTOLOGICAL IMAGES USING A DEEP NEURAL NETWORK**

**Abstract.** Segmentation of medical images is one of the key tasks of biomedical informatics, especially in the context of cancer diagnosis. The task of precise segmentation of cell nuclei is particularly relevant and necessary to identify morphological changes in tissues. However, the main challenges and problems in this area remain the variability of image quality, limited amounts of available data, and the need to ensure the high accuracy and stability of deep learning models. This study analysed the impact of ten data augmentation techniques, including the addition of random noise of varying intensity, on the cell nucleus segmentation model's performance. The experiment also specialises in techniques using artificial noise addition, simulating real-world conditions such as lighting variations, artefacts, and defects during sample preparation. Two types of noise were used to add: additive Gaussian noise and uniform random noise with an intensity from minus 0.05 to 0.05, which demonstrated a significant effect on the generalizing ability of the model, improving its resistance to heterogeneous data. The architecture used was based on a modified UNet model with the introduction of the CBAM module, which focuses the model's attention on significant areas of the image. The module has been added to the decoding part of the model architecture. For the experiments, two reference datasets CryoNuSeg and MoNuSeg were combined with preprocessing, including patching and image format conversion. Applied augmentation techniques included horizontal and vertical reflection, random rotation, contrast change, elastic deformation, and noise addition. In addition, augmentation combinations were investigated during the experiments. The study results showed that the techniques of horizontal and vertical reflection augmentation and random rotation achieved minimal losses, while the accuracy of the models exceeded ninety per cent. The contrast change technique demonstrated the most balanced performance, providing an average intersection ratio over the union of 0.928 and an accuracy of 92.2 per cent. The data from the study results emphasize the importance of using artificial noise addition to increase the model's resistance to artefacts and data variability, as well as the use of combined augmentation techniques. In the future, combined augmentation techniques may become the basis for the development of adaptive algorithms capable of effectively working with heterogeneous biomedical images

**Keywords.** Histological images, cancer, nuclei segmentation, convolutional neural networks, attention module, augmentation.

### **Авторлар туралы мәлімет**

Койшиева Дина Еркиновна	Ғ.Даукеев атындағы Алматы энергетика және коммуникация университеті, М094-Ақпараттық технологиялар мамандығының магистранты, Алматы, Қазақстан, E-mail: <a href="mailto:d.koishiyeva@aes.kz">d.koishiyeva@aes.kz</a>
Сыдыбаева Мадина Алданышовна	Ғ.Дәукеев атындағы Алматы энергетика және коммуникация университетінің ақпараттық жүйелер және киберқауіпсіздік кафедрасының аға оқытушысы, Алматы, Қазақстан, E-mail: <a href="mailto:m.sydybaeva@alt.edu.kz">m.sydybaeva@alt.edu.kz</a>
Бельгинова Сауле	PhD, Тұран Университетінің қауымдастырылған профессоры, Алматы қ., Қазақстан, E-mail: <a href="mailto:sbelginova@gmail.com">sbelginova@gmail.com</a>
Жаксыбаев Айдын Мадиярович	«Технологиялық машиналар мен жабдықтар» мамандығы бойынша магистр, Шәкәрім университеті, «ОлжаПРОЕКТ» ЖШС басшысы, Өскемен, Қазақстан, E-mail: <a href="mailto:olzha2010@mail.ru">olzha2010@mail.ru</a>
Ерсаинова Жансая	«АТЖЗЖМ» оқытушысы, Д.Серікбаев атындағы ШҚТУ, Өскемен қ., Қазақстан, E-mail: <a href="mailto:Zhansaya.ersayynova@mail.ru">Zhansaya.ersayynova@mail.ru</a>

**Сведение об авторах**

Койшиева Дина Еркиновна	Магистрант по специальности М094-Информационные технологии, Алматинский университет энергетики и связи имени Г.Даукеева, Алматы, Казахстан, E-mail: <a href="mailto:d.koishiyeva@aes.kz">d.koishiyeva@aes.kz</a>
Сыдыбаева Мадина Алданышовна	Старший преподаватель кафедры «Информационных систем и кибербезопасности», Алматинский университет энергетики и связи имени Г.Даукеева, Алматы, Казахстан, E-mail: <a href="mailto:m.sydybaeva@alt.edu.kz">m.sydybaeva@alt.edu.kz</a>
Бельгинова Сауле	PhD, ассоц. профессор, Университета Туран, к.т.н. г. Алматы, Казахстан, E-mail: <a href="mailto:sbelginova@gmail.com">sbelginova@gmail.com</a>
Жаксыбаев Айдын Мадиярович	Магистр по специальности «Технологические машины и оборудование», Шакарим университет, Руководитель ТОО «ОлжаПРОЕКТ» г. Усть-Каменогорск, Казахстан, E-mail: <a href="mailto:olzha2010@mail.ru">olzha2010@mail.ru</a>
Ерсаинова Жансая	Преподаватель «ШИТиИС», ВКТУ им.Д. Серикбаева, г. Усть-Каменогорск, Казахстан, E-mail: <a href="mailto:Zhansaya.ersayynova@mail.ru">Zhansaya.ersayynova@mail.ru</a>

**Information about the authors**

Koyshieva Dina	Master's student in the specialty M094-Information Technology, Almaty University of Power Engineering and Telecommunications named after G. Daukeyev, Almaty, Kazakhstan, E-mail: <a href="mailto:d.koishiyeva@aes.kz">d.koishiyeva@aes.kz</a>
Sydybaeva Madina	Senior Lecturer, Department of Information Systems and Cybersecurity, Almaty University of Power Engineering and Telecommunications named after G. Daukeyev, Almaty, Kazakhstan, E-mail: <a href="mailto:m.sydybaeva@alt.edu.kz">m.sydybaeva@alt.edu.kz</a>
Belginova Saule	PhD, Associate Professor of Turan University, Almaty, Kazakhstan, E-mail: <a href="mailto:sbelginova@gmail.com">sbelginova@gmail.com</a>
Zhaksybaev Aidyn	Master's degree in Technological Machines and Equipment, Shakarim University, Head of «OlzhaПРОЕКТ» LLP, Ust-Kamenogorsk, Kazakhstan, E-mail: <a href="mailto:olzha2010@mail.ru">olzha2010@mail.ru</a>
Ersainova Zhansaya	Teacher of " SITaIS ", D. Serikbayev EKTU, Ust-Kamenogorsk, Kazakhstan, E-mail: <a href="mailto:Zhansaya.ersayynova@mail.ru">Zhansaya.ersayynova@mail.ru</a>