



## ПРИМЕНЕНИЕ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ АВТОМАТИЗИРОВАННОЙ СЕГМЕНТАЦИИ И КЛАССИФИКАЦИИ КТ СНИМКОВ ПАРНАЗОНОСНЫХ ПАЗУХ ПРИ ХРОНИЧЕСКОМ РИНОСИНУСИТЕ: РАЗРАБОТКА И ВАЛИДАЦИЯ МОДЕЛИ

Нурбек Нурмахаммад угли Тухтасинов  
Жамшидбек Абдувохид угли Абдухошимов

Ассистент кафедры Оториноларингологии Андижанского  
государственного медицинского института, г. Андижан,  
Узбекистан. tukhtasinovnn@gmail.com

Магистрант кафедры Оториноларингологии Андижанского  
государственного медицинского института, г. Андижан,  
Узбекистан. jvakhaboff8@gmail.com  
<https://doi.org/10.5281/zenodo.15599980>

### ARTICLE INFO

Qabul qilindi: 25-May 2025 yil  
Ma'qullandi: 28-May 2025 yil  
Nashr qilindi: 31-May 2025 yil

### KEYWORDS

хронический риносинусит,  
КТ, взрослого населения, deep  
learning.

### ABSTRACT

*Цель. Разработать и валидировать конвейер  
глубокого обучения для автоматической  
сегментации четырёх основных околоносовых пазух  
и бинарной классификации снимков на «здоровые» и  
«с патологией хронического риносинусита».*

*Материалы и методы. Для сегментации  
использован открытый датасет NasalSeg (130 КТ  
томограмм с вручную размеченными пазухами) и  
фреймворк nnU Net, автоматически подбирающий  
гиперпараметры под данные. Для классификации —  
внутренняя выборка из 200 пациентов (100  
контрольных, 100 с подтверждённым хроническим  
риносинуситом по критериям EPOS) и архитектура  
ResNet 18, обученная на трёх стандартных  
проекциях томограмм. Модели оценивали по  
метрикам Dice, IoU (для сегментации) и Accuracy,  
Sensitivity, Specificity, AUC (для классификации).  
Применена стратифицированная 5 кратная кросс  
валидация.*

### Введение

Хронический риносинусит (ХРС) — распространённое воспалительное заболевание околоносовых пазух, поражающее до 12 % взрослого населения и приводящее к значительному снижению качества жизни и росту затрат здравоохранения (Fokkens et al., 2020). Диагноз и планирование лечения в первую очередь основываются на компьютерной томографии (КТ), где врач вручную сегментирует пазухи и оценивает степень затемнения слизистой (Lund & Maskau, 1993). Однако ручная разметка трёхмерных КТ-томограмм требует 1–2 часов работы

радиолога на одного пациента и плохо масштабируется в условиях роста объёма исследований (Morgan et al., 2022).

Методы глубокого обучения (deep learning) уже доказали эффективность в автоматической сегментации анатомических структур и классификации патологий в разных областях (Çiçek et al., 2016; Ronneberger et al., 2015). В контексте околоносовых пазух архитектура U-Net и её 3D-вариации продемонстрировали Dice  $\approx 0,90-0,98$  на задачах сегментации (Choi et al., 2022; Morgan et al., 2022; Whangbo et al., 2024). Для классификации состояния пазух (наличие/отсутствие ХРС или эндотипизация) применялись сверточные сети ResNet и DenseNet с AUC  $\approx 0,90-0,96$  (Lin et al., 2024; Hung et al., 2023).

Цель настоящей работы — объединить обе задачи в одном конвейере: автоматическую сегментацию ключевых пазух и последующую на основе объёмно-морфометрических признаков классификацию томограмм на здоровые и больные ХРС, используя современные фреймворки nnU-Net и PyTorch.

## Материалы и методы

### Данные

#### 1. Сегментация:

- Датасет NasalSeg (130 аксиальных КТ-томограмм с разметкой левой/правой верхнечелюстных, лобных, клиновидных и решётчатых пазух) (Zhang et al., 2024).

#### 2. Классификация:

- Собственная база из 200 пациентов (100 контрольных без клинических и эндоскопических проявлений ХРС, 100 с верифицированным ХРС по критериям EPOS 2020). Каждому пациенту соответствуют три проекции КТ (аксиальная, корональная, сагиттальная); подтверждение диагноза — ЭОС-эндоскопия и мазки из соустьев.

### Предобработка

- Ресемплинг вокселей к размеру  $1 \times 1 \times 1$  мм.
- Нормализация интенсивности по окну HU  $[-300, 1200]$  с масштабированием в  $[0, 1]$ .
- Кадрирование области пазух: автоматическое определение региона интереса по пороговой маске воздуха и костных структур.
- Аугментации для сегментации: случайные повороты ( $\pm 15^\circ$ ), сдвиги ( $\pm 10\%$ ), масштабирование  $(0,9-1,1)$ , Gaussian-шум.
- Для классификации: случайные флип, контраст-/яркостная сдвиг-аугментация.

### Модель сегментации

- Использовали **nnU-Net v2** (Isensee et al., 2021), который автоматически настраивает архитектуру U-Net, гиперпараметры и стратегии аугментации под заданные данные.

- Обучение проводилось 1 000 эпох, оптимизатор — AdamW ( $\text{lr} = 1e-3$  с циклическим снижением до  $1e-5$ ), батч = 2 тома.

- Разбиение NasalSeg: 5-fold cross-validation (5 групп по 26 пациентов), при каждом фолде оставляли один фолд на тест и четыре — на обучение с валидацией внутри.

### Модель классификации

- Архитектура **ResNet-18** (He et al., 2016), модифицированная для трёхканального ввода (аксиальная, корональная, сагиттальная).
- Предобученные веса ImageNet, fine-tuning на наших проекциях.
- Оптимизатор — Adam (lr = 1e-4, weight\_decay = 1e-5); батч = 32; 100 эпох.
- Метки: 0 — «контроль», 1 — «ХРС».
- Кросс-валидация: стратифицированный 5-fold на 200 наборах (40 тест, 160 train+val в каждом фолде).

**Оценка качества**

• **Сегментация:**

- Dice Similarity Coefficient (DSC), Intersection over Union (IoU), Hausdorff95 (HD95).

• **Классификация:**

- Accuracy, Sensitivity (Recall), Specificity, Precision, F1-score, ROC-AUC.
- Для обоих этапов рассчитали среднее и стандартное отклонение по всем фолдам.

**Результаты**

**Сегментация**

Структура пазухи	Dice (mean ± SD)	IoU (mean ± SD)	HD95 (мм)
Верхнечелюстные пазухи	0,97 ± 0,01	0,94 ± 0,02	0,4
Лобные пазухи	0,95 ± 0,02	0,91 ± 0,03	0,5
Клиновидные пазухи	0,96 ± 0,02	0,92 ± 0,03	0,6
Решётчатый лабиринт (L+R)	0,94 ± 0,02	0,89 ± 0,03	0,7
<b>Среднее по всем пазухам</b>	<b>0,96 ± 0,02</b>	<b>0,93 ± 0,03</b>	—

- Время инференса одной КТ-томограммы: ~35 с на GPU NVIDIA RTX 2080Ti.
- Наибольшие ошибки сегментации при выраженном мукозном отёке в решётчатых пазухах, где границы размыты.

**Классификация**

Метрика	Значение (%)
Accuracy	94,8 ± 1,2
Sensitivity	95,2 ± 1,5
Specificity	94,4 ± 1,7
Precision	94,5 ± 1,3
F1-score	94,8 ± 1,1
ROC AUC	0,960 ± 0,008

- Модель уверенно различала контроль и ХРС; средняя ROC-кривая показана на Рис. 1.
- Анализ Grad-CAM показал, что сеть фокусируется на области пазух, в частности на утолщённых участках слизистой.

**Обсуждение**

Полученные результаты подтверждают, что современный конвейер глубокого обучения позволяет достигать **уровня эксперта-радиолога** в задаче сегментации

околоносовых пазух (Dice  $\approx$  0,96) и с высокой точностью классифицировать наличие ХРС по КТ-томограммам (AUC  $\approx$  0,96).

#### 1. Сравнение с литературой.

○ Choi et al. (2022) получили Dice  $\approx$  0,90 на 3D U-Net для одной пары пазух. Наши результаты выше, что обусловлено и использованием nnU-Net и расширенной предобработкой.

○ Morgan et al. (2022) показали Dice  $\approx$  0,98 при двухэтапном U-Net на КЛКТ; наша сегментация близка к их показателям, но на полномарочном КТ.

○ Lin et al. (2024) для классификации эндотипа CRSwNP использовали ResNet-18 и получили Accuracy  $\approx$  95 % и AUC  $\approx$  0,96, что сходно с нашими метриками по бинарному разделению контроль/ХРС.

#### 2. Клиническая значимость.

Автоматическая сегментация и классификация позволяют:

○ Сократить трудозатраты радиолога в 5–10 раз.

○ Выдавать объективные количественные показатели (объем пазух, процентное заполнение).

○ Предоставлять предварительный диагноз (наличие ХРС) до прочтения окончательного отчета.

#### 3. Ограничения.

○ Собственная выборка для классификации ограничена одним центром; требуется внешняя валидация на мультицентрических данных.

○ В случаях очень выраженного мукозного отёка сегментация менее точна — необходимы дополнительные обучающие примеры таких паттернов.

○ Конвейер пока не интегрирован в PACS; требуется разработка удобного интерфейса.

#### 4. Перспективы.

○ Расширить задачу классификации: прогноз эндотипа (эозинофильный vs. неэозинофильный ХРС) на основе признаков сегментации и радиомики.

○ Интеграция AI-модулей в клинические протоколы — «AI-assisted reporting» в PACS и эндоскопических системах.

○ Доработка модели для 3D-навигатора при эндоскопических операциях (FESS).

#### Заключение

Разработанный конвейер глубокого обучения с использованием nnU-Net и ResNet-18 показал высокую эффективность в автоматической сегментации и классификации КТ-снимков околоносовых пазух при хроническом риносинусите. Результаты сопоставимы с экспертными показателями радиологов, а скорость анализа в разы превосходит ручной метод. Это обосновывает целесообразность внедрения подобных систем в клиническую практику для повышения объективности и экономии времени при диагностике и планировании лечения ХРС.

#### Список литературы:

1. Choi, H., Jeon, K. J., Kim, Y. H., Ha, E.-G., Lee, C., & Han, S.-S. (2022). Deep learning-based fully automatic segmentation of the maxillary sinus on cone beam computed tomographic images. *Scientific Reports*, 12, Article 14009. <https://doi.org/10.1038/s41598-022-18436-w>

2. Morgan, N., Van Gerven, A., Smolders, A., de Faria Vasconcelos, K., Willems, H., & Jacobs, R. (2022). Convolutional neural network for automatic maxillary sinus segmentation on cone beam computed tomographic images. *Scientific Reports*, 12, Article 7523. <https://doi.org/10.1038/s41598-022-11483-3>
3. Preda, F., Morgan, N., Van Gerven, A., Nogueira Reis, F., Smolders, A., Wang, X., Nomidis, S., Shaheen, E., Willems, H., & Jacobs, R. (2022). Deep convolutional neural network based automated segmentation of the maxillofacial complex from cone beam computed tomography: A validation study. *Journal of Dentistry*, 124, 104238. <https://doi.org/10.1016/j.jdent.2022.104238>
4. Whangbo, J., Lee, J., Kim, Y. J., Kim, S. T., & Kim, K. G. (2024). Deep learning based multi class segmentation of the paranasal sinuses of sinusitis patients based on computed tomographic images. *Sensors*, 24(6), 1933. <https://doi.org/10.3390/s24061933>
5. Du, W., Kang, W., Lai, S., Cai, Z., Chen, Y., Zhang, X., & Lin, Y. (2024). Deep learning in computed tomography to predict endotype in chronic rhinosinusitis with nasal polyps. *BMC Medical Imaging*, 24, Article 25. <https://doi.org/10.1186/s12880-024-01203-w>
6. Hua, H., Li, S., Xu, Y., Chen, S., Kong, Y., & Yang, R. (2023). Differentiation of eosinophilic and non eosinophilic chronic rhinosinusitis on preoperative computed tomography using deep learning. *Clinical Otolaryngology*, 48(2), 330–338. <https://doi.org/10.1111/coa.14110>
7. Zeng, D., Li, M., Chen, J., & Wang, S. (2023). Abnormal maxillary sinus diagnosing on CBCT images via object detection and classification with YOLOv5. *Journal of Oral Rehabilitation*, 50(12), 1465–1474. <https://doi.org/10.1111/joor.13585>
8. Hung, K. F., Ai, Q. Y. H., King, A. D., Bornstein, M. M., Wong, L. M., & Leung, Y. Y. (2022). Automatic detection and segmentation of morphological changes of the maxillary sinus mucosa on cone beam computed tomography images using a three dimensional convolutional neural network. *Clinical Oral Investigations*, 26(8), 3987–3998. <https://doi.org/10.1007/s00784-021-04365-x>
9. Chowdhury, N. I., Smith, T. L., Chandra, R. K., & Turner, J. H. (2019). Automated classification of osteomeatal complex inflammation on computed tomography using convolutional neural networks. *International Forum of Allergy & Rhinology*, 9(1), 46–52. <https://doi.org/10.1002/alr.22196>
10. Huang, R., Nedanoski, A., Fletcher, D. A., Singh, N. P., Schmid, J., Young, P. J., Stow, N., Bi, L., Traini, D., Wong, E. H., Phillips, C., Grunstein, R. R., & Kim, J. (2019). An automated segmentation framework for nasal computational fluid dynamics analysis in computed tomography. *Computers in Biology and Medicine*, 115, 103505. <https://doi.org/10.1016/j.combiomed.2019.103505>