



Сегментація зображень з використанням нейронних мереж

**Виконала студентка КН-4 Плахотна Дар'я
Керівник: кандидат технічних наук Бучко О. А.**

Мета



Розробити, експериментально обґрунтувати, та кількісно оцінити методику семантичної сегментації МРТ-зображень головного мозку, визначивши архітектурно-тренувальні фактори, що впливають на точність і ресурсну ефективність.

Проблематика

- Традиційні методи демонструють низьку здатність до узагальнення.
- Висока чутливість до шумів та варіацій освітлення.
- Відсутні механізми адаптації до нових даних або умов.
- Обмежений обсяг доступних анотованих даних.

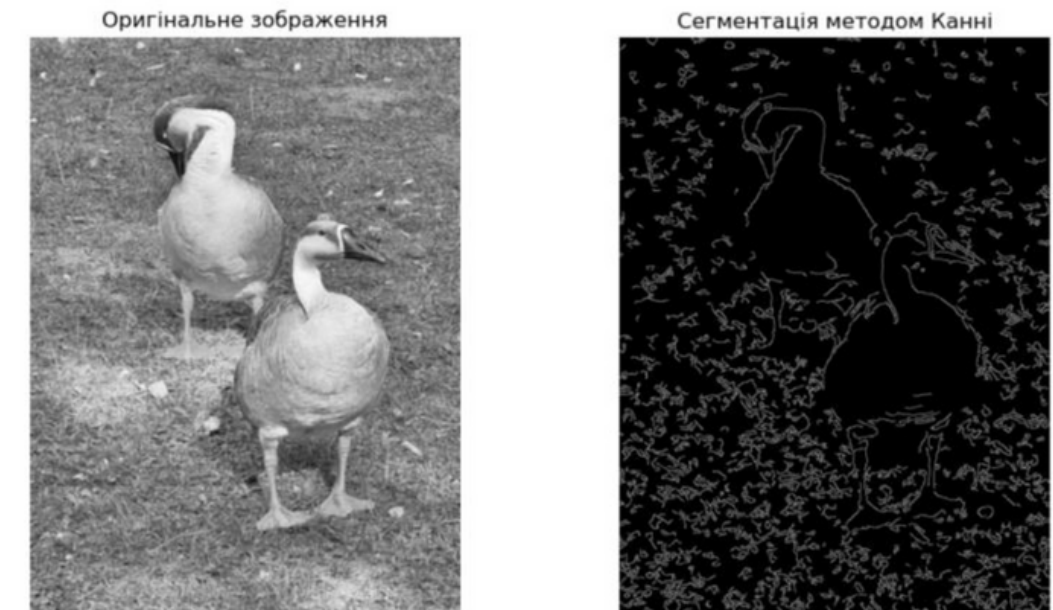


Рис. 1.3. – Приклад виділення країв методом Канні




Рис. 1.5. – Приклад сегментації методом вододілу

Задачі

- Здійснити порівняльний аналіз архітектур згорткових нейронних мереж для семантичної сегментації пухлин мозку на МРТ-зображеннях.
- Впровадити та програмно реалізувати self-supervised підхід попереднього навчання енкодера на основі передбачення кута обертання.
- Дослідити вплив самоконтрольованого попереднього навчання на точність сегментації в умовах обмеженої кількості анотованих даних.

Використаний датасет

- Містить 369 МРТ-обстежень пацієнтів із пухлинами головного мозку
- Кожен об'єм має 4 модальності сканування: T1, T1Gd, T2, FLAIR
- Маски сегментації включають 3 класи патології: 1) некротична тканина, 2) перифокальний набряк, 3) активна пухлина
- Виконано нормалізацію, перетворення формату, аугментацію для покращення навчання моделей




Рис. 3.1. – Поперечний зріз мозку одного з пацієнтів у чотирьох магнітно-резонансних модальностях: T1 (анатомічне зображення), T1Gd (контрастно-підсилене), T2 (патології), FLAIR (набряк)

Джерело: BraTS2020


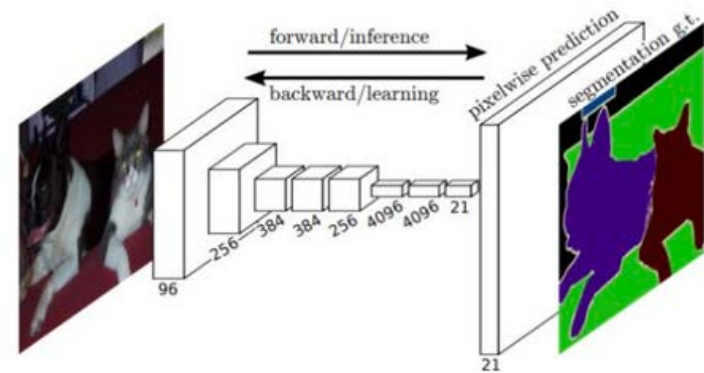


Рис. 3.2. – Маски сегментації для одного зрізу

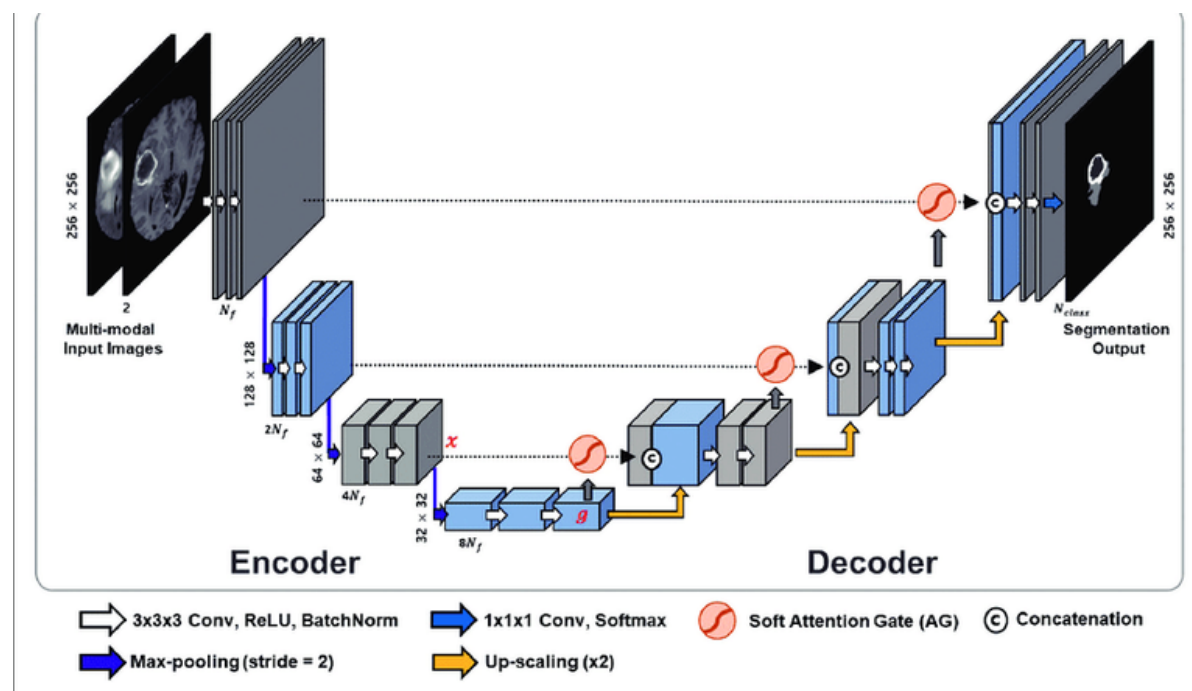
Джерело: BraTS2020

Архітектури, що тестувались

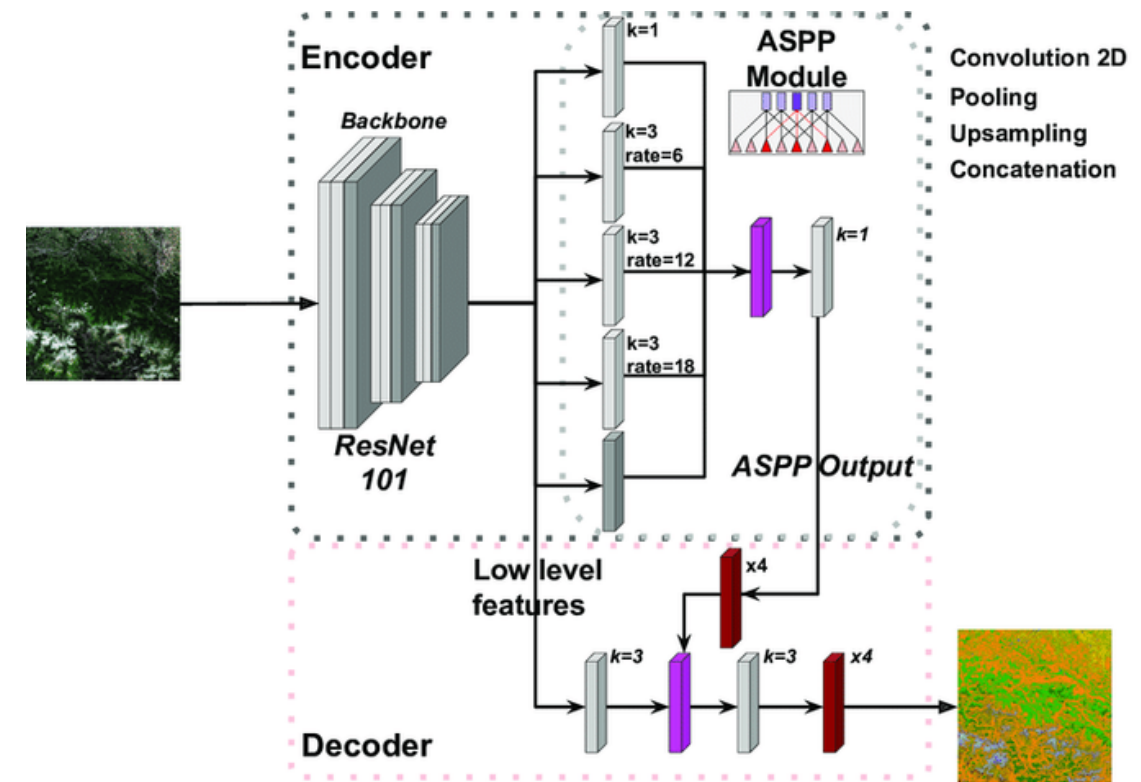
- FCN



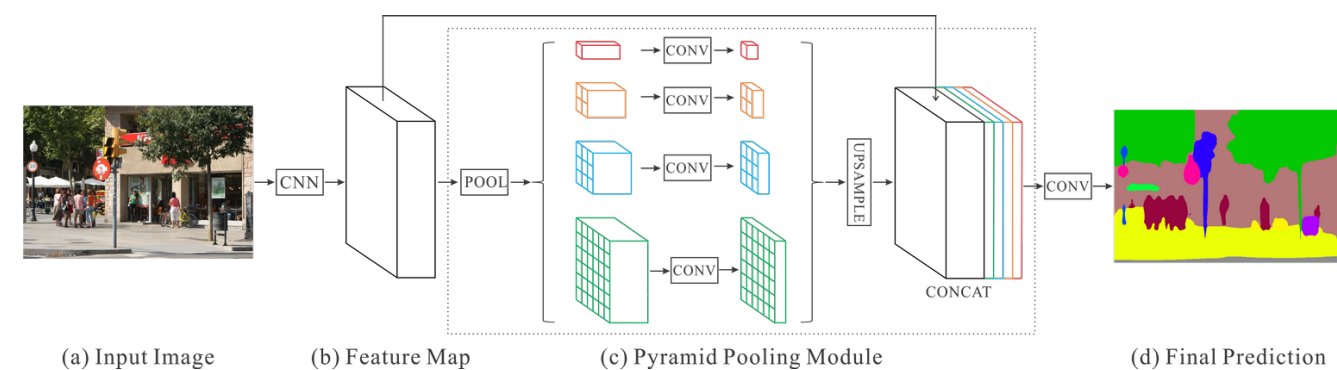
- Attention U-Net



- DeepLabv3+



- PSPNet



Порівняльні результати (1/2)

$$Dice = \frac{2TP}{2TP+FP+FN}$$

Модель	Фон (0)	Некроз (1)	Набряк (2)	Активна пухлина (3)	Середнє значення
FCN	0.975	0.744	0.802	0.763	0.821
Attention U-Net	0.982	0.784	0.843	0.813	0.856
DeepLabv3+	0.978	0.767	0.828	0.796	0.842
PSPNet	0.974	0.719	0.794	0.755	0.811

Табл. 3.1. – Порівняльні значення Dice-коефіцієнтів для тестової вибірки

Порівняльні результати (2/2)

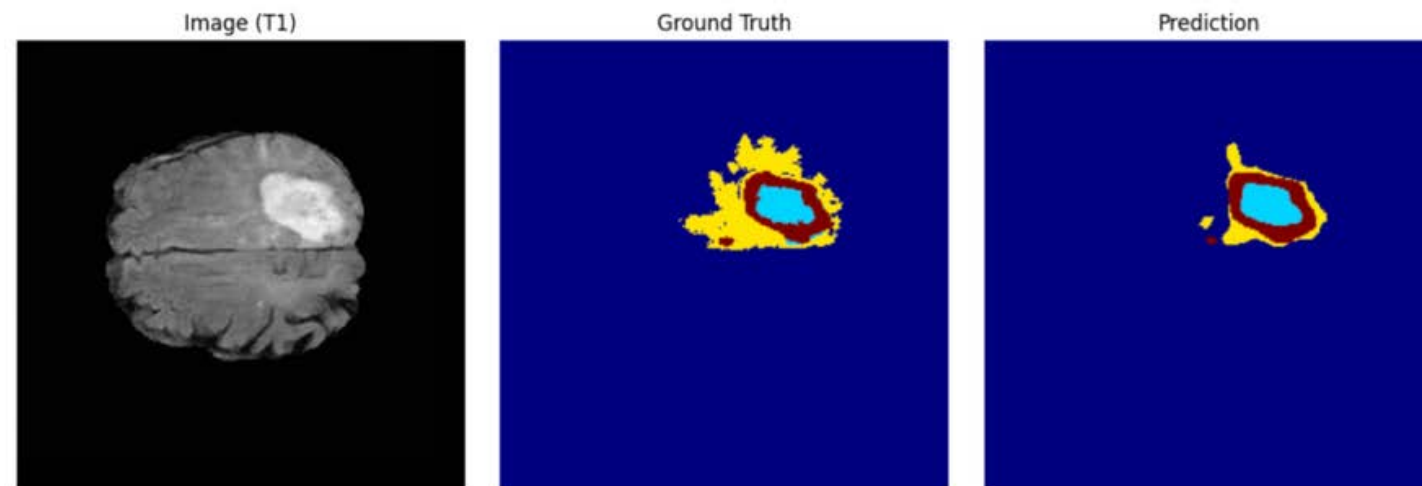


Рис. 3.4. – Приклад результату сегментації моделі FCN: зображення T1, ground truth і прогноз.

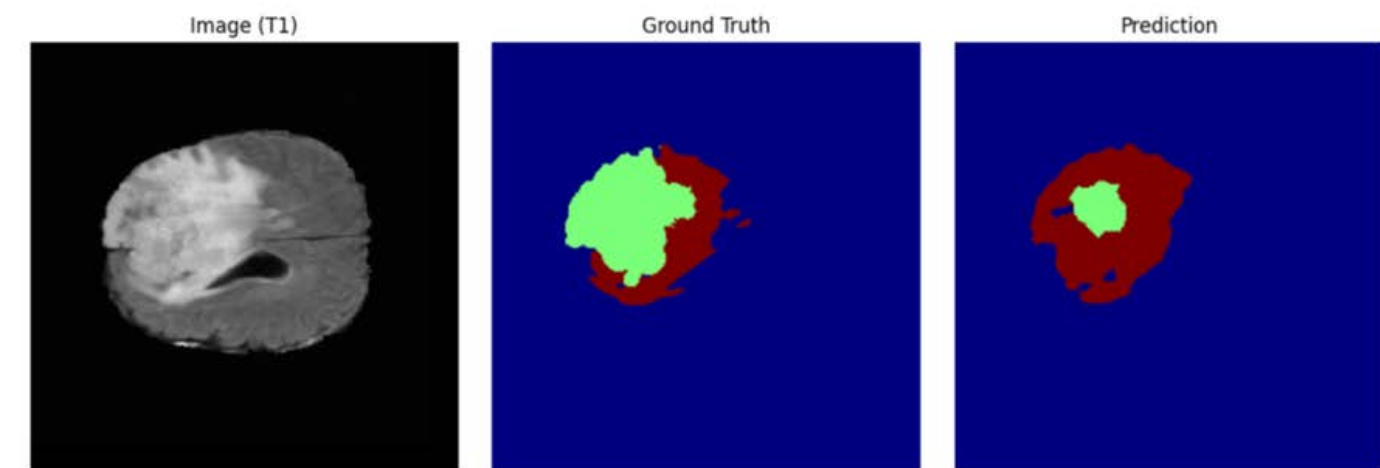


Рис. 3.5. – Приклад результату сегментації моделі Deeplabv3+: зображення T1, ground truth і прогноз.

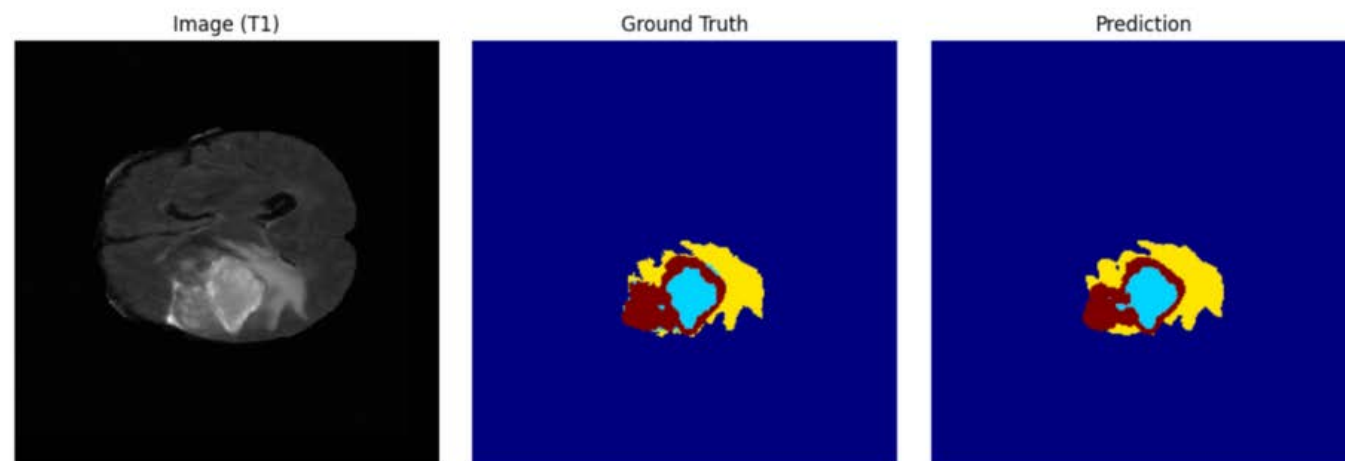


Рис. 3.7. – Приклад результату сегментації моделі Attention U-Net: зображення T1, ground truth і прогноз.

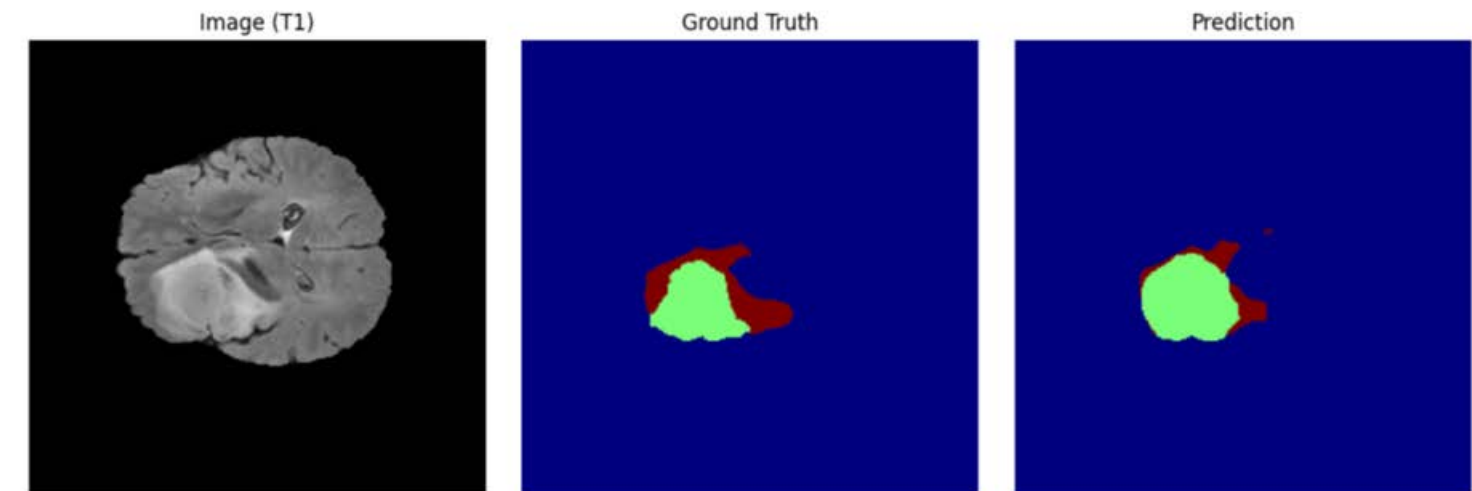



Рис. 3.6. – Приклад результату сегментації моделі PSPNet: зображення T1, ground truth і прогноз.

Обмеження традиційного навчання у медичній сегментації

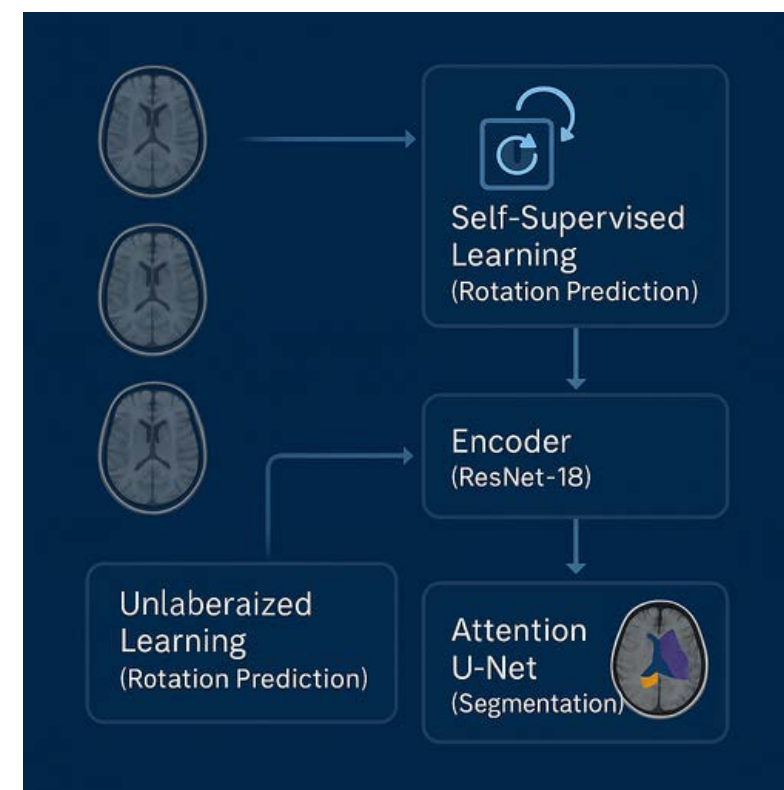
- Якість сегментації істотно залежить від обсягу анотованих даних.
- Розмітка зображень потребує ручної праці експертів
- Це створює вузьке місце для застосування глибокого навчання в клінічних умовах

Для підвищення якості сегментації в умовах дефіциту анотацій необхідно впроваджувати альтернативні підходи до навчання — зокрема, **самоконтрольовані методи**



Self-Supervised Learning (1/2)

- *Self-supervised learning (SSL)* — це парадигма попереднього навчання, у якій модель засвоює представлення даних без використання анотованих прикладів, опираючись на внутрішню структуру вхідного сигналу.
- Навчання відбувається шляхом розв'язання штучно сформульованої допоміжної задачі (pretext task), що не потребує ручної розмітки.



Self-Supervised Learning (2/2)

- Використано pretext-завдання предикції кута обертання зображення (0° , 90° , 180° , 270°) для самоконтрольованого навчання
- Енкодер ResNet-18 адаптовано для 4-канального медичного вводу та навчено без анованих масок
- Отримані ваги перенесено до сегментаційної моделі Attention U-Net з наступним донавчанням на розмічених даних

```
[SSL] Epoch 1: Train loss=0.2443, Acc=0.8911
[SSL] Epoch 2: Train loss=0.1746, Acc=0.9116
[SSL] Epoch 3: Train loss=0.1683, Acc=0.9143
[SSL] Epoch 4: Train loss=0.1684, Acc=0.9127
[SSL] Epoch 5: Train loss=0.1646, Acc=0.9147
[SSL] Epoch 6: Train loss=0.1640, Acc=0.9156
[SSL] Epoch 7: Train loss=0.1628, Acc=0.9161
[SSL] Epoch 8: Train loss=0.1633, Acc=0.9141
[SSL] Epoch 9: Train loss=0.1613, Acc=0.9182
[SSL] Epoch 10: Train loss=0.1576, Acc=0.9171
```

Результати з SSL

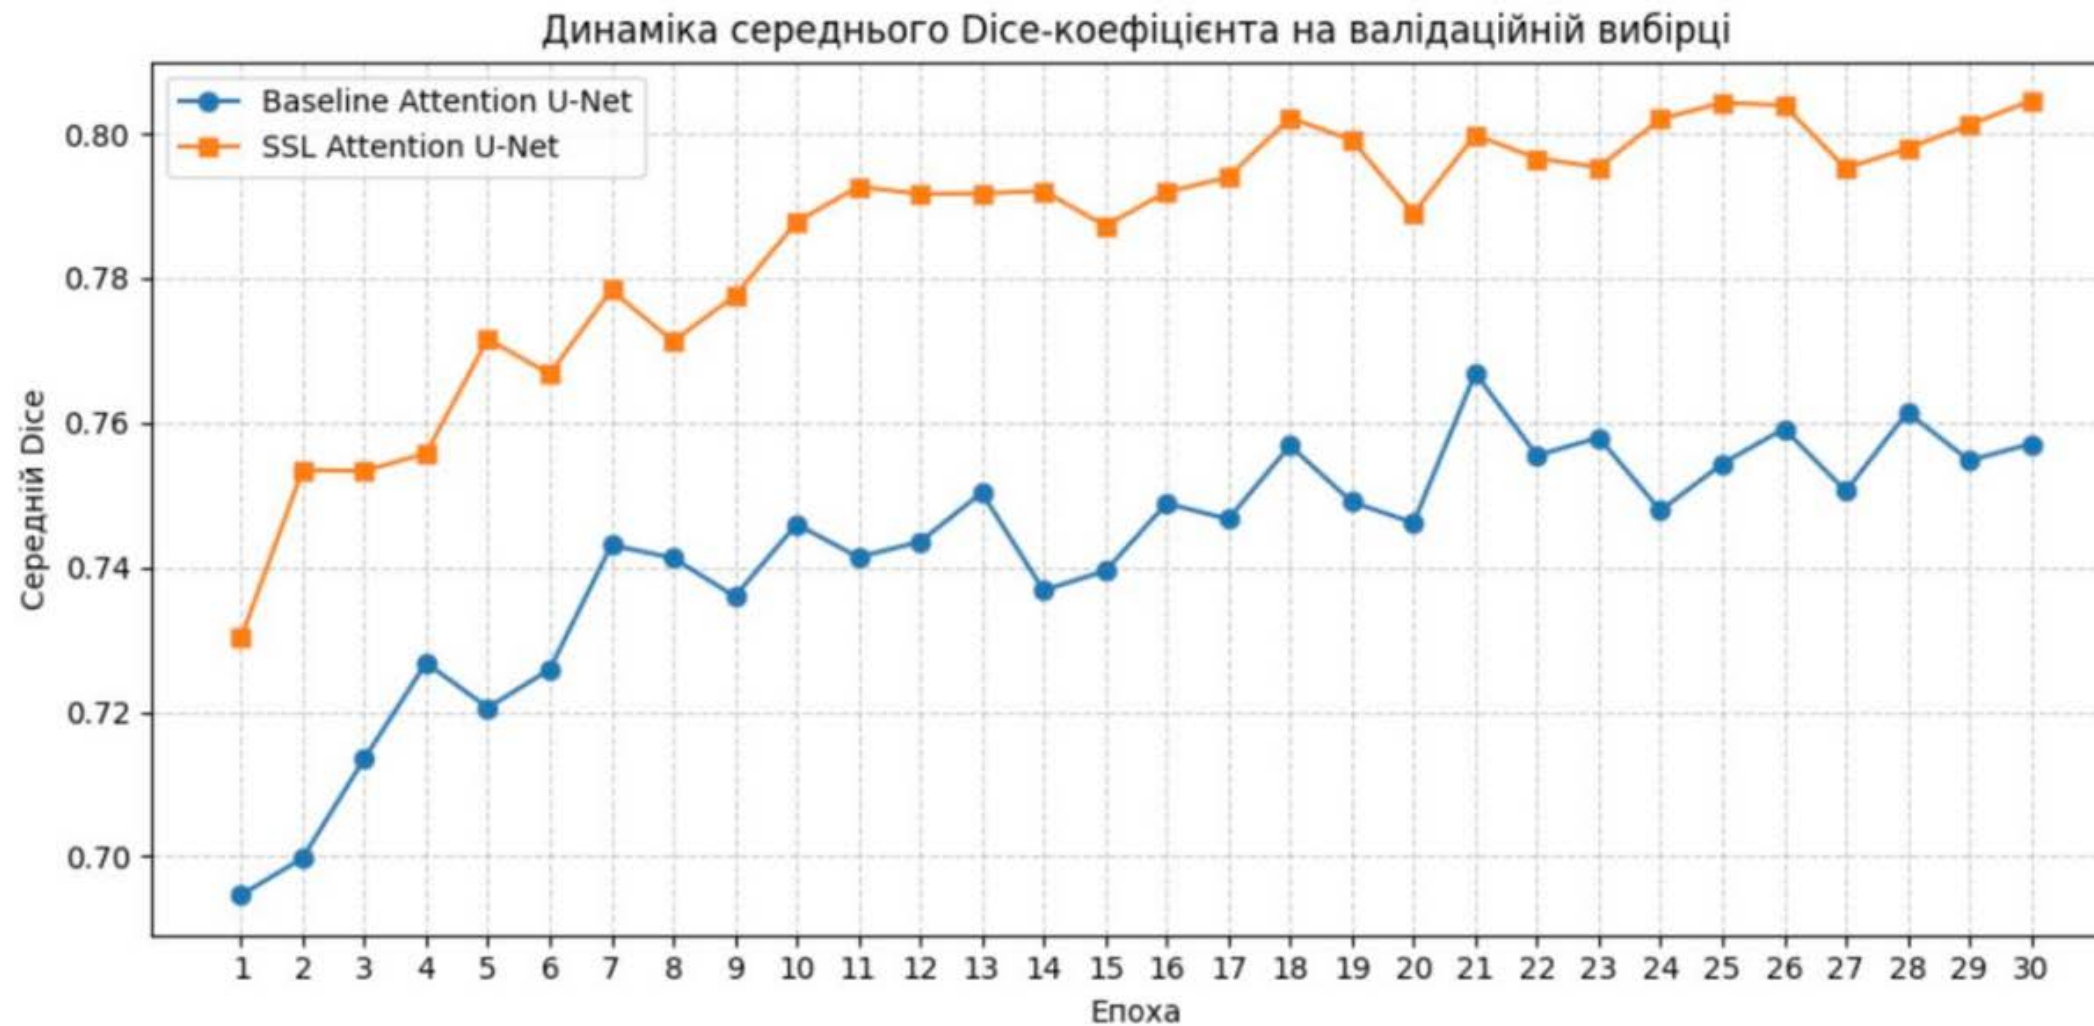


Рис. 3.8. – Динаміка Dice на валідаційній вибірці для обох моделей

Висновки

- Архітектура Attention U-Net продемонструвала найвищу точність сегментації та стабільність результатів серед розглянутих моделей.
- Використання self-supervised попереднього навчання енкодера істотно підвищує якість сегментації в умовах дефіциту анотованих даних.
- Запропонована методика є перспективною для впровадження у високоточних задачах медичної діагностики, де доступ до розмічених даних є обмеженим.

Дякую за увагу