

Юрочкін Владислав Володимирович
студент

*Національного технічного університету України
«Київський політехнічний інститут імені Ігоря Сікорського»*

Юрочкин Владислав Владимирович
студент

*Национального технического университета Украины
«Киевский политехнический институт имени Игоря Сикорского»*

Yurochkin Vladyslav

*Student of the
National Technical University of Ukraine
«Igor Sikorsky Kyiv Polytechnic Institute»*

Науковий керівник:

Аверьянова Ольга Анатоліївна

старший викладач

*Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»*

DOI: 10.25313/2520-2057-2021-8-7398

**СЕГМЕНТАЦІЯ ОБЛАСТЕЙ КРОВОВИЛИВІВ
В МОЗКУ НА КТ ЗНІМКАХ ЗА ДОПОМОГОЮ
ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ**

**СЕГМЕНТАЦІЯ ОБЛАСТЕЙ КРОВОИЗЛИЯНИЙ
НА КТ СНИМКАХ МОЗГА С ПОМОЩЬЮ
СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ**

**SEGMENTATION OF HEMORRHAGE AREAS
ON BRAIN CT IMAGES USING CONVOLUTIONAL
NEURAL NETWORKS**

Анотація. В роботі розглянуто побудову системи візуалізації сегментації крововиливів на КТ зображеннях мозку шляхом створення та навчання згорткової нейронної мережі для оптимізації процедури пошуку патології в КТ діагностиці.

Ключові слова: нейронна мережа, CNN, UNet, сегментація, комп'ютерна томографія, крововиливи.

Аннотация. В работе рассмотрено построение системы визуализации сегментации кровоизлияний на КТ изображениях мозга путем создания и обучения сверточной нейронной сети для оптимизации процедуры поиска патологии в КТ диагностике.

Ключевые слова: нейронная сеть, CNN, UNet, сегментация, компьютерная томография, кровоизлияния.

Summary. The paper considers the construction of a system for visualization of hemorrhage segmentation on brain CT images by creating and training a convolutional neural network to optimize the procedure for finding pathology in CT diagnostics.

Key words: deep learning, neural network, CNN, UNet, segmentation, computed tomography, hemorrhages.

Постановка проблеми. Визначення області крововиливу на КТ-зображеннях мозку, пов'язаного з великим масштабом просторової та структурної мінливості в кожному КТ скануванні, присутності шуму, а також наявності складної просторової особливості у низькому контрасті між крововиливами та нормальними регіонами, допоможе рентгенологу та неврорадіологу. Сегментація зображень за допомогою глибокого машинного навчання, включаючи використання згорткових нейронних мереж, зарекомендувала себе як надійний інструмент сегментації зображень. Вона широко використовується для розділення однорідних областей як перший та найважливіший компонент діагностики та лікування.

Аналіз останніх досліджень і публікацій. В останні десятиліття багато дослідників прагнули розробити алгоритми та методології обробки зображень, що дозволяють легко і бездоганно ідентифікувати відхилення, наявні в сканованій області [1; 2; 3]. На відміну від існуючих підходів до сегментації областей крововиливів на знімках КТ, глибокі CNN (згорткові нейронні мережі) автоматично засвоюють дедалі складніші особливості з даних. До переваг згорткових мереж в порівнянні з методами, що оперують попиксельними та морфологічними операціями, можна віднести їх здатність знаходити на зображеннях окремі об'єкти або значущі частини об'єктів, які також називають високорівневими ознаками (тоді як пікселі зображення можна вважати низькорівневими ознаками). Ця їх здатність дозволяє ефективно розрізняти об'єкти на зображенні.

Луї з командою [6] запропонував структуровану залишкову структуру, повністю згорнуту мережу (Res-FCN) для отримання автоматизованої сегментації інсульту на основі багатоспектральних МРТ-зображень. Абулнага та ін. [4] використовував PSPNet, мережеву архітектуру, яка використовує об'єднання

пірамід для надання глобальної та локальної контекстної інформації для отримання сегментації інсульту. Більшість останніх методів глибокого навчання спрямовані на виявлення або сегментацію ішемічного інсульту [5]. Менше проведено роботи щодо семантичної сегментації крововиливів, і, наскільки відомо, жоден підхід до семантичної сегментації не продемонстрував конкурентних показників порівняно з експертами-людьми.

Метою є вирішення проблеми сегментації локальних областей з крововиливами на зображеннях комп'ютерної томографії мозку.

Вступ. Комп'ютерна томографія, більш відома як КТ — це неінвазивна діагностична процедура візуалізації, яка надає змогу отримати горизонтальні або осьові зображення мозку. На вихід томограф повертає КТ-зображення внутрішніх органів, кісток, м'яких тканин та судин. Будь-який тип кровотечі всередині черепа або мозку є невідкладною медичною допомогою. Найпоширенішими причинами крововиливів є травми, геморагічний інсульт та субарахноїдальний крововилив через розрив аневризми. Ключем для диференціальної діагностики є місце розташування крововиливів, особливо при нетравматичних кровотечах. Точна сегментація області є важливою частиною планування етапів клінічного лікування. В останні десятиліття багато дослідників прагнули розробити алгоритми та методології обробки зображень, що дозволяють легко і швидко ідентифікувати відхилення, наявні в сканованій області.

Датасет. Для дослідження був використаний набір даних, що складається із зображень КТ у форматі jpg розміру 512x512 (px). Для 82 пацієнтів існує 2500 зображень сканів КТ головного мозку (рис. 1). На одного пацієнта припадає приблизно 30 фрагментів зображень. 318 зображень масок містять

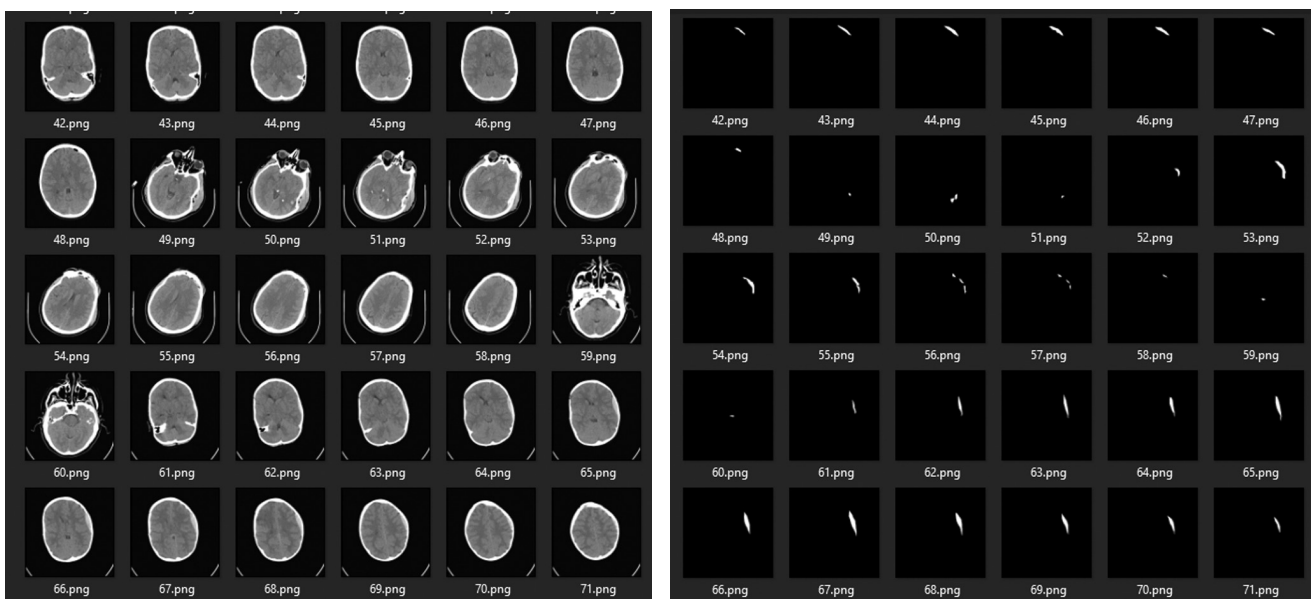


Рис. 1. Матеріали для дослідження (КТ скани мозку та маски з крововиливами)

патологію. Середній та старій вік пацієнтів становили 27,8 та 19,5 відповідно. 46 пацієнтів — чоловіки, а 36 — жінки. Кожен зріз неконтрастних КТ було зроблено двома рентгенологами, які реєстрували типи крововиливів, якщо крововилив стався або стався перелом. Рентгенологи також окреслили при наявності області крововиливу на кожному зрізі [8].

Препроцесінг. Для тренування мережі подібна кількість даних доволі замала, до того ж присутній значимий дисбаланс класів зображень для навчання. В роботі використовувався підхід розширення даних (data augmentation) через вертикальні та горизонтальні перевертання зображень, для подолання таких проблем, як: нерівномірний розподіл зображень за класами (тільки 318 зображень з крововиливами) та відсутність достатньої кількості навчальних даних.

Архітектура. Згорткові нейронні мережі (CNN) — це модифікація звичайної нейронної мережі з повно зв’язними шарами, яка в основному орієнтована на роботу з зображеннями. Звичайна нейронна мережа при роботі з зображенням ніяк не враховує близькість окремих пікселів, на вхід їй можна подати тільки зображення в витягнутому в вектор вигляді. В той самий час при збільшенні кількості згортальних шарів CNN рецептивні поля збільшуються, захоплюючи більшу кількість пікселів, і нейронна мережа знаходить все більш високорівневі ознаки на зображенні та дозволяє відтворювати найскладніші нелінійні залежності.

В роботі використовувалась згорткова мережа архітектури UNet [7]. Сам тип мережі присвячений вирішенню проблеми прогнозування та локалізації захворювання шляхом розрізнення кордонів через класифікацію кожного пікселя. Модель має форму типу «U». Архітектура є симетричною і складається з двох основних частин — ліву частину називають контракуючим шляхом, який також називають кодером, який складається загалом згортковим процесом; права частина — експансивний шлях, також відомий як декодер,

який складається з транспонованих двовимірних згорткових шарів (рис. 2).

В роботі за базовий блок згортки відповідає структура, зображена на рис. 3. Батч-нормалізація дуже корисна для конвергенції моделі. Виходи лінійної операції, такої як згортка, після батч-нормалізації пропускають через нелінійну функцію активації. Раніше використовувались гладкі нелінійні функції, такі як сигмоїдна або гіперболічна дотична (tanh), оскільки вони є математичними зображеннями поведінки біологічних нейронів. Найпоширенішою функцією нелінійної активації, що використовується в даний час, є випрямлена лінійна одиниця «ReLU».




Рис. 3. Блок згортки

Функція втрат: UNet використовує функцію втрат для кожного пікселя зображення. Вона вимірює сумісність між вихідними прогнозами мережі (через пряме розповсюдження) та заданими основними мітками істинності. Під час навчання використовувалась бінарна кросс-ентропія, що ідеально підходить під поставлену задачу.




Рис. 2. Архітектура UNet

Шлях згортки — типова архітектурі згорткової нейронної мережі. Він складається з повторного застосування двох блоків згортки 3×3 , за якими слідує «ReLU» і операція максимального об'єднання (2×2 в ступені 2) для зниження розміру. На кожному етапі понижуваної дискретизації канали властивостей подвоюються.

Кожен підвищуючий дискретизатор в частині декодера (права частина U) ініціалізує нові пікселі шляхом використання середньозваженого значення пікселів (з використанням білінійної інтерполяції), щоб в кінцевому підсумку досягти бажаного розміру. Після того, як представлення для цих нових пікселів додано, наступні згортки покращують деталізацію в них, оскільки шлях триває по шляху декодера мережі, а потім збільшує масштаб ще на один крок і подвоює розміри.

Для вихідного шару для бінарної сегментації використовується блок згортки 1×1 з «сигмоїдною» функцією.

Конкуреноспроможність моделі базується на двох ключових підходах UNet: U-подібній структурі та пропускових з'єднаннях. Навіть при використанні малого набору даних при навчанні UNet дозволяє отримати оптимальний результат.

Тренування та гіперпараметри. Вхідні зображення та відповідні їм сегментаційні карти (маски)

використовувались для навчання мережі із реалізацією стохастичного градієнтного спуску. Вибір моделі складався з порівняння результатів сегментації експертів та прогнозу натренованої мережі (рис. 4). Для цього на обраній архітектурі, але використовуючи різні вхідні дані тренування, функції витрат та різні параметри оптимізації обчислень, що впливали на ваги класів, були отримані моделі та оцінені результати їх сегментації на тестовій групі, яка складається з 50 зображень крововиливів різних типів та нормальних КТ зображень.

Було визначено, що при навчанні мережі архітектури UNet краще використовувати приклади, де маска містить шуканий клас. Модель тренувалась 18 епох, використовувалась алгоритм оптимізації для стохастичного градієнтного спуску Адам та бінарна крос-ентропія як функція втрат. Модель витратила на навчання приблизно 8 годин.

Метрики оцінки ефективності. Ефективність системи сегментації зображень оцінюється за допомогою стандартних і відомих показників, які можна використовувати для оцінки ефективності сегментації моделей глибокого навчання з точки зору точності.

TP, FP, FN та TN визначені на рис. 5.

Точність (*accuracy*) — представляє відсоток пікселів зображення, які правильно класифіковані. Але




Рис. 4. Приклад роботи мережі: верх-ліво — вхідне зображення, низ-ліво — зображення, що хочемо отримати, верх-право — вихідне зображення мережі з порогом 0.5, низ-право — маска, отримана в результаті роботи мережі

Category	Actual Disease	Actual No Disease
Predicted Disease	True Positive (TP)	False Positive (FP)
Predicted No Disease	False Negative (FN)	True Negative (TN)

Рис. 5. Визначення скорочень

маючи дисбаланс класів використовувалась точність для кожного класу, яка визначає відсоток правильно позначених пікселів для кожного класу, а потім визначає їх середнє значення. Збалансована точність дає майже ті ж результати, що і оцінка *ROC AUC*.

Precision представляє частку пікселів хвороби в результатах автоматичної сегментації, які збігаються з основними пікселями хвороби.

$$precision = \frac{TP}{TP + FP}$$

Recall показує, яку частку об'єктів позитивного класу (крововилив) з усіх об'єктів позитивного класу знайшов алгоритм.

$$recall = \frac{TP}{TP + FN}$$

Результат. Отримана модель роботи мережі виявилась оптимальною для задачі сегментації крововиливів на КТ мозку (рис. 6). та демонструє ефективність та практичну точність в свої показаннях (табл. 1).

Таблиця 1

Результат оцінки ефективності мережі

	Model
Balanced accuracy	0.7934
Recall	0.6013
Precision	0.3969

Висновки. В роботі були представлені результати побудови, навчання та застосування мережі типу CNN для виявлення патології, а саме крововиливів на КТ сканах мозку. В задачі сегментації крововиливів існує проблема малої кількості даних для навчання, для її подолання використовувались методики для розширення датасету та зміна вагів класів при навчанні. При використанні більш об'ємних і різноманітних навчальних вибірок похибки роботи нейронних мереж будуть зменшуватися. Після того як мережа навчена, її можна вважати зручним інструментом аналізу патологій.

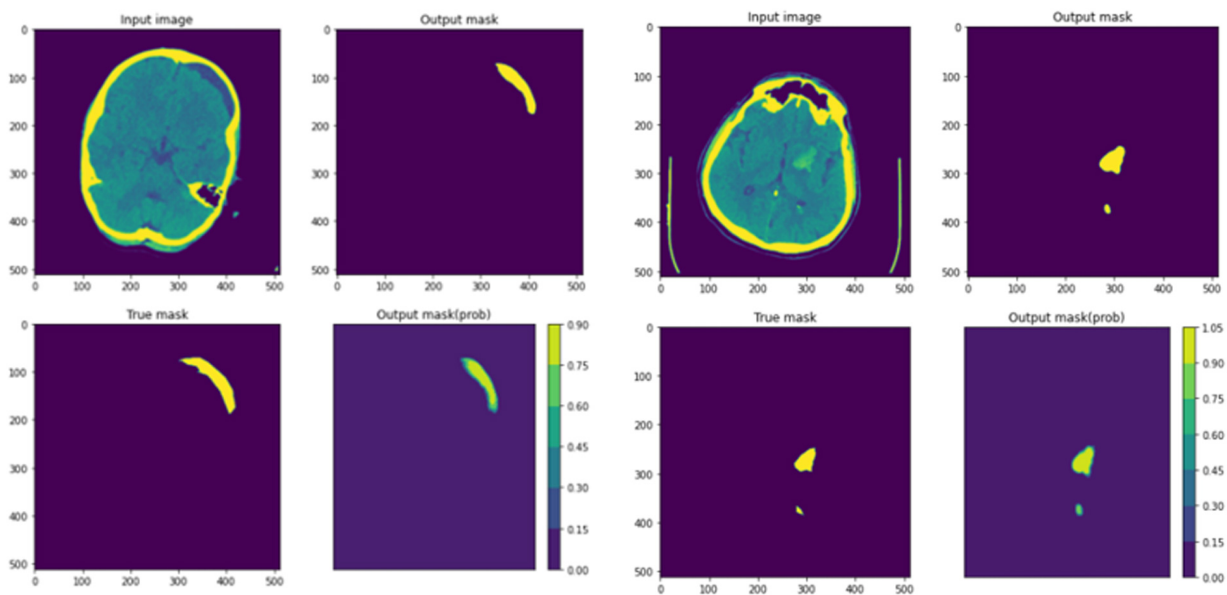


Рис. 6. Результат роботи мережі

Жирепарыпа

1. Chen E. L., Chung P. C., Chen C. L., Tsai H. M., Chang C. I. An automatic diagnostic system for CT liver image classification. *IEEE Trans Biomed Engg.* 1998. No 45. P. 783–93.
2. Gletsos M., Mougiakakou S. G., Matsopoulos G. K., Nikita K. S., Nikita A. S., Kelekis D. A computer-aided diagnostic system to characterize CT focal liver lesions: Design and optimization of a neural network classifier. *IEEE Trans Inform Technol Biomed.* 2003. No 7. P. 153–62.
3. Kyaw M. M. Computer-Aided Detection system for Hemorrhage contained region. *International Journal of Computational Science and Information Technology.* 2013. No 1(1). P. 11–16.
4. Abulnaga, S.M. and J. Rubin. Ischemic stroke lesion segmentation in ct perfusion scans using pyramid pooling and focal loss. in *International MICCAI Brainlesion Workshop.* Springer, Cham, 2018. P. 352–363.
5. Kamnitsas K., Bai W., Ferrante E., et al. Ensembles of multiple models and architectures for robust brain tumour segmentation. In: *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries.* Cham, 2018. P. 450–462.
6. Liu Z., et al. Towards clinical diagnosis: Automated stroke lesion segmentation on multi-spectral MR image using convolutional neural network. *IEEE Access,* 2018. No 6. P. 57006–57016.
7. Ronneberger Olaf, Fischer Philipp, Brox Thomas U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS,* 2015. Vol. 9351. P. 234–241.
8. Hssayeni M. Computed Tomography Images for Intracranial Hemorrhage Detection and Segmentation (version 1.0.0). *PhysioNet.* 2019. URL: <https://doi.org/10.13026/w8q8-ky94>