

АЛГОРИТМ СЕГМЕНТАЦІЇ НОВОУТВОРЕНИХ ПУХЛИН НА МРТ ЗОБРАЖЕННІ ГОЛОВНОГО МОЗКУ ЗА ДОПОМОГОЮ КОМБІНАЦІЙ НЕЙРОННИХ МЕРЕЖ

Помпа К. В.,

kostiantynpompa@gmail.com,

Максименко В. Б., д.м.н., проф.

maksymenko.vitaliy@gmail.com

Факультет біомедичної інженерії

Національний технічний університет України

“Київський політехнічний інститут ім. Ігоря Сікорського”

Київ, Україна

Реферат – Запропоновано алгоритм сегментації пухлин головного мозку на зображеннях МРТ, що реалізований на основі декількох ансамблів нейронних мереж. При ітерації алгоритму обчислення використовуються виходи базових нейронних мереж як вхідні данні для нової тренованої нейронної мережі, яка в подальшому виступає об'єднувачем для того, щоб відрізнити рубцеву тканину або не вражену тканину від клітин пухлини. Даний підхід має складний узагальнюючий характер, але, таким чином, вдається підвищити якість сегментації пухлини комбінацією нейронних мереж. Особливість алгоритму полягає в тому, що індивідуальний результат для кожного класифікатора визначається на основі натренованих раніше моделей, потім воксель класифікується як частина пухлини, якщо хоча б один з класифікаторів визначить його як пухлину. Далі, результат сегментації базових класифікаторів потрапляє на вхід вже навченого мета-класифікатора, який приймає остаточне рішення щодо приналежності вокселя на зображенні до клітин пухлини.

Ключові слова – сегментація зображення, нейронні мережі, нейромережеві ансамблі, комбінація нейронних мереж, пухлини головного мозку, МРТ зображення.

I. ВСТУП

У зв'язку з величезною різноманітністю анатомічних структур і їх ознак на томограмах головного мозку, а також через проблеми розпізнавання їх серед патологій, МРТ можна вважати трудомістким процесом, що вимагає від лікаря високої кваліфікації і великих часових витрат. Крім цього, оцінка знімків МРТ часто здійснюється візуальним способом, без вимірювання яскравості і контрастності, що може привести до помилки. При візуальному дослідженні патологія може бути прийнята помилково за нормальну анатомічну область мозку.

Розробка запропонованих методів лежить в основі автоматизованого алгоритму визначення характеру неоднорідностей на знімках, застосування якого в процесі діагностики захворювань

головного мозку дозволить підвищити діагностичну ефективність, допоможе лікарю більш точно оцінити томограми, менше часу витрачаючи на аналіз, що призведе до скорочення лікарських помилок. Автоматизація процесу визначення природи новоутворень дозволить підвищити практичну цінність системи і відкрити нові шляхи подальшого її вдосконалення.

II. ОГЛЯД ЛІТЕРАТУРИ

Досліди в області застосування нейронних мереж для сегментації МРТ зображень підтверджують, що сегментація за допомогою ансамблів нейронних мереж є точнішою, ніж результати сегментації окремих нейромереж. Комбінація нейронних мереж з множиною копій працює краще, аніж, якщо використовувати одну копію. Погано навчені нейронні мережі є

негативним наслідком багатьох алгоритмів налаштування. Набагато краще використовувати множину копій, навіть, якщо їх ефективність значно менша, ніж у інших. Ще більша ефективність може бути досягнута через детальне планування класифікації ансамбля, використовуючи доступні параметри й навчання різних копій на різних підмножинах даних. Перевіркою ефективності роботи є перехресна перевірка, яка визначає наскільки результати статистичного аналізу узагальнюються на незалежному наборі даних. Ця міра ефективності використовується тоді, і тільки тоді, коли нейромережева комбінація навчилася і вимірює істинну цільову функцію. Також, перехресна перевірка може бути використана в подальшому для оптимізації архітектури нейронної мережі шляхом підбору кількості латентних нейронів і кількості шарів мережі [5].

Більшість алгоритмів використовують методи тестового навчання, щоб знайти найефективнішу архітектуру та шаблон налаштувань для нейронної мережі, а потім усі наступні класифікації делегують в найкращу мережу. Такий підхід є доцільним, проте використання ансамблів мереж має значну перевагу, але потребує визначення вагового коефіцієнту ω , що є проблемою оптимізації при наявності багатьох локальних мінімумів. Тобто, глобальні методи оптимізації на стиках локальних мінімумів видають оптимальні параметри (ω), які сильно відрізняються починаючи від першої ітерації і до наступних. Це характерно в тому випадку, коли ми зіткнуємося з різними початковими точками та різною послідовністю навчальних прикладів, що свідчить про випадковий характер. Така випадковість диференціює помилки нейронних мереж, тому що вони будуть допускати їх на різних ітераціях вводу. Очевидно, що нейронні мережі матимуть різні значення вагового коефіцієнта, що різним чином формує різні узагальнення на будь-якій з ітерацій. Оскільки кожна нейронна мережа допускає помилки на різних множинах входу, то можна стверджувати, що комбінаційне рішення буде менш хибним, ніж результат будь-якої з окремих нейронних мереж.

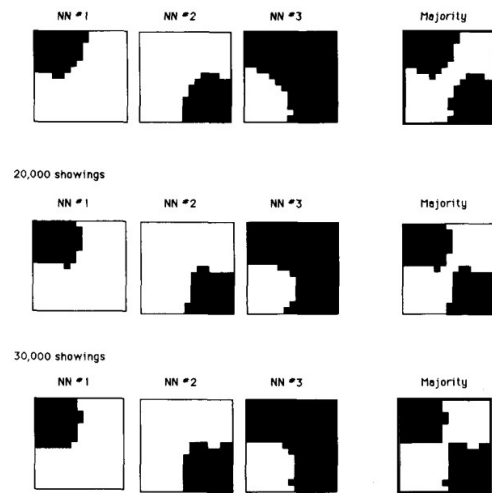


Рис.1 – Три мережі навчені визначати приналежність вхідних x, y до I і III квадранту – чорні, або другий і четвертий – білі. На рисунку показана класифікація кожної мережі окремо, і рішення ансамблю мереж.

На рис.1 показано, що три нейронні мережі навчені визначати точки в першому і третьому квадранті. Хоча одна з трьох окремих нейромереж правильно не визначила точки, ансамбль цих нейромереж визначив їх успішно.

III. ПОСТАНОВКА ПРОБЛЕМИ

Проблема сегментації пухлин головного мозку є найбільш актуальною проблемою для обробки та аналізу зображень МРТ на сьогоднішній день. Протягом останніх 15 років для вирішення завдання сегментації пухлин головного мозку були вивчені і оцінені багато різноманітних методів. Ранні роботи в цій області пропонують вирішити проблему шляхом виявлення аномалій на зображенні [1, 2]. Наглядними роботами такого типу можуть бути праці, в основі яких лежить ідея зіставлення знімків пацієнта зі знімками в атласі не хворих пацієнтів. Основною перевагою цього методу є те, що запропоновані рішення не потребують навчання. Однак, недоліком цього підходу є те, що неможливо використати один і той же алгоритм на пухлинах меншого розміру. Інший клас вирішення даного завдання закладений в ідеї використання алгоритмів навчання з учителем, такі як метод опорних векторів [3] або метод “випадкових лісів” [4]. Це необхідно щоб використовувати незалежність між базовими моделями, а

похибку зменшувати методом усереднення. І тому ці моделі мають низьку взаємну кореляцію і широке різноманіття даних. Моделі можуть оброблювати великий набір ознак і працювати досить ефективно в найбільш поширених випадках. Однак, через дуже дискримінаційний характер розвитку пухлин головного мозку важко визначити правильний набір ознак і створити ефективну модель. У зв'язку з цим, сучасні дослідження в області сегментації зображень звертаються до нейронних мереж.

IV. МЕТА ДОСЛІДЖЕННЯ

Для того, щоб покращити якість сегментації був сформований нейромережний ансамбль. Більшість ансамблевих алгоритмів при створенні однорідних базових моделей використовують єдиний базовий метод навчання. Це призводить до однорідності комбінацій, але існують алгоритми, які використовують гетерогенні моделі (моделі різних типів). В результаті утворюються гетерогенні комбінації. Щоб ансамблі були більш точними, ніж будь-який їх окремих член, базові моделі повинні бути максимально різноманітними. Іншими словами, чим більше інформації надходить до об'єднувача від базових класифікаторів, тим вище точність комбінації. Деякі ансамблеві методи не визначають об'єднувача, але для тих методів, які це роблять, існує три алгоритми об'єднання.

Один з алгоритмів працює по принципу "більшості голосів" (majority voting). Ідея полягає в наступному: для кожного вокселя вхідних знімків, обраховується індивідуальний результат для кожної нейронної мережі на основі натренованих раніше моделей, потім воксель класифікується частиною пухлини тоді і тільки тоді, коли більшість нейромереж класифікує його як пухлину, в іншому випадку воксель є здоровою клітиною мозку. Наприклад, якщо в ансамблі 2 нейронні мережі, то воксель буде класифікований як частина пухлини, якщо хоча б одна з нейронних мереж визначить його як нездорову клітину. Якщо в ансамблі 3 нейронних мережі, тоді необхідно, щоб дві нейромережі класифікували воксель як

клітину пухлини, щоб в результаті роботи ансамбля воксель також вважався враженою клітиною. Але, якщо навчити об'єднувач порівнювати вагові коефіцієнти, то ансамбль працюватиме по принципу "зваженої більшості голосів" (weighted majority voted). і Naive Bayes, а також підхід "classifier selection", в якому рішення по даному об'єкту приймає один класифікатор ансамблю. Очевидно, що нейронні мережі матимуть різні значення вагового коефіцієнта, що рівним чином формує різні узагальнення на будь-якій з ітерацій. Така випадковість диференціює помилки нейронних мереж, тому що вони будуть допускати їх на різних ітераціях вводу. Тому запропонований алгоритм, виходячи базових класифікаторів якого розглядаються як вхідні дані для нового класифікатора, стає об'єднувачем. Цей підхід використовує "складне узагальнення", "узагальнення через навчання", або просто stacking [6].

V. МАТЕРІАЛИ І МЕТОДИ

Використано набір відкритих даних, який включає в себе МРТ знімки 100 пацієнтів з пухлиною, як з високим рівнем злоякісності, так і з низькою [7, 8]. Вхідні дані – зображення МРТ, зроблені в режимах T1, T2, T1Gd, Flair. Для всіх пацієнтів було виділені границі пухлини на кожному знімку. Усі інтенсивності на знімках були попередньо приведені до гаусівського розподілу із середнім 0 і стандартним відхиленням 1. Таким чином, для кожного вокселя (елемент об'ємного зображення, що містить значення інтенсивності знімка) було обчислено нове значення за такою формулою:

$$\frac{img\ mean}{std} \quad (1)$$

де *img* – значення інтенсивності для даного вокселя; *mean* – середнє значення інтенсивності; *std* – стандартне відхилення інтенсивностей.

Відповідно до досліджень [8], такий спосіб значно підвищує якість роботи нейронної мережі. Також для кожного знімка була обчислена маска зображення головного мозку. Маска подається на вхід нейронної мережі, щоб під час навчання

мережа навчалася тільки на зображенні мозку, не враховуючи фон.

Запропоновано використання ансамблю з 10 моделей згорнутих нейронних мереж – WNET, Multi-class WNET, Multi-class WNET + TTA, 3D UNet, 3D UNet + TTA, Cascade networks, Cascade networks + TTA, DEERMEDIC (T1), DEERMEDIC (T1+T2) експериментально визнані кращими для вирішення завдання сегментації пухлини головного мозку.

В Tensorflow [9] реалізовано 3D UNet [10], багаторівневі WNet і каскадні мережі [11] з використанням NiftyNet [12]. Адаптивна оцінка моменту використовувалася для навчання (ADAM) [13] з початковою швидкістю навчання 10^{-3} , вага розпад 10^{-7} і максимальну ітерацію 20k. Розмір патча для підготовки становив $96 \times 96 \times 96$ для 3D UNet і $96 \times 96 \times 19$ для багаторівневих WNet. Розмір групи становив 2 і 4 для цих двох мереж відповідно. Для каскадних мереж наслідували стандартні конфігурації [11]. Навчальний процес був реалізований на GeForce RTX 2080. Для навчання використовувалася функція THE DICE LOSS [14].

Для нейронної мережі WNET [15] використовувалася стандартна конфігурація і параметри, описані в оригінальній статті [16]. Модель була навчена на наборі даних з використанням всіх чотирьох режимів для кожного пацієнта. В оригінальну конфігурацію DEERMEDIC [16] були внесені наступні зміни в архітектуру мережі: як функції активації була обрана функція SELU[17] замість PReLU. Це дозволило прискорити процес навчання даної мережі та поліпшити якість розпізнавання пухлин. Також, для DEERMEDIC було навчено дві моделі. Перша версія моделі була навчена тільки на знімках в режимах T1 і T2. Даний вибір обумовлений тим, що T1 і T2 є найбільш поширеними режимами для МРТ. Такі режими, як Flair і T1Gd використовуються не у всіх клініках і лікарнях, тому застосування тільки двох режимів робить модель більш універсальною для подальшого використання. Друга версія DEERMEDIC була навчена виключно з

використанням T1 знімків. Дана модель була навчена, щоб вивчити поведінку моделі в тому випадку, коли на вході є тільки один режим МРТ. Для всіх трьох мереж вихідний набір даних був розділений на 3 частини: навчання (близько 70%), валідація (20%) і тестова множина (10%).

Щоб реалізувати їх взаємодію в ансамблі було застосовано алгоритм, який використовує виходи базових нейронних мереж як вхідні дані для нової тренованої нейронної мережі, яка в подальшому виступає об'єднувачем для того, щоб відрізнити рубцеву тканину від клітин пухлини. Даний алгоритм носить складний узагальнюючий характер, але, таким чином, вдається підвищити якість сегментації комбінацією нейронних мереж.

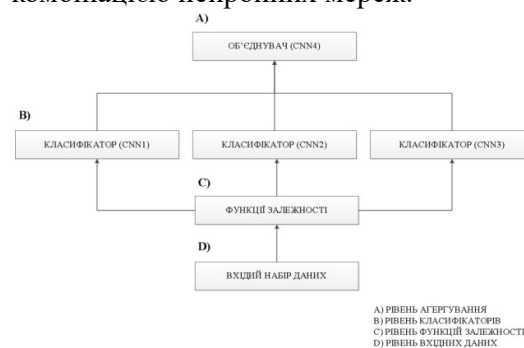


Рис. 2 – Рівні функціонування та складові алгоритму

Складові алгоритму – базові класифікатори, які будуть витягати з потоку даних складні функції закономірностей (найчастіше неявних), а об'єднувач стане класифікатором, який агрегує ці функції (рис.2). На рівні агрегування відбувається об'єднання даних, отриманих від класифікаторів, і агрегування єдиного виходу. При ітерації алгоритму обчислення використовуються виходи базових класифікаторів як вхідні дані для нової тренованої нейронної мережі, яка в подальшому виступає об'єднувачем. Ключова ідея алгоритму полягає в наступному: індивідуальний результат для кожного класифікатора визначається на основі натренованих раніше моделей, потім воксель класифікується як частина пухлини, якщо хоча б один з класифікаторів визначить його як пухлину, і потрапляє на вхід мета-класифікатора. Наприклад, якщо в комбінації 3 класифікатора, то воксель буде класифікований як частина пухлини у

випадку, якщо хоча б одна з нейронних мереж визначить його як не здорову клітину. Далі інформація з класифікаторів передається на вже навчений об'єднувач, який порівнює вхідні данні з даними, на яких проводилось його навчання (рис.3).



Рис. 3 – Схема роботи алгоритму

Вся корисна робота відбувається на рівні класифікаторів. Постає питання, які класифікатори використовуємо – однакові чи різні? При підході bagging використовуються однакові класифікатори. Вибір класифікатора і його обґрунтування - важливий елемент роботи. Класифікатори мають бути різними: з різною ініціалізацією, параметрами навчання та навчальними наборами. Важлива швидкість класифікатора: моделі не повинні навчатися годинами. Моделі класифікації повинні давати результат передбачення краще 50%. І, нарешті, важлива стабільність класифікатора, щоб результати передбачення мали невеликий розкид. На рівні функцій знайдених закономірностей використовуються всі предиктори або тільки індивідуальні підмножини для кожного класифікатора. У даному випадку використовуються спеціальний алгоритм. Піксельний алгоритм пропонує класифікувати пікселі в суміжні області на основі сірих рівнів. Даний метод використовує локальну інформацію – значення рівнів сірого суміжних пікселів, або, глобальну інформацію – загальний розподіл рівнів сірого суміжних пікселів. Рівні сірого відображають інтенсивність світла у кожному пікселі. На рівні вхідних даних і маніпуляцій з ними відбувається подача даних на вхід нейронної мережі для навчання [18 - 23].

VI. РЕЗУЛЬТАТИ ТА ОБГОВОРЕННЯ

Для оцінки якості роботи даного алгоритму при заданій нейромережівій комбінації була вибрана метрика DICE COEFFICIENT [24], найбільш використовувана для оцінки якості сегментації зображень:

$$DC(A, B) = \frac{2|A \cap B|}{|A \cup B|}$$

де A і B – істинна і прогнозована область.

DICE COEFFICIENT приймає значення від 0 до 1. При 1 – абсолютно правдиве прогнозування.

DICE COEFFICIENT – недиференційована метрика, і саме тому в якості функціонала була вибрана середня крос-ентропія (log loss), де в якості індикаторів класу були 1, якщо воксель є пухлиною, і 0 в іншому випадку. На виході нейромережа видавала приналежність вокселя до першого класу. Для обчислення даних результатів використовувалася тестова множина, вибрана з вихідних даних випадковим чином заздалегідь. Результати, отримані для заданих нейромережових комбінацій, можна побачити в Таблиці 1.

Таблиця 1 – Показник DICE COEFFICIENT для зазначених комбінацій нейронних мереж

| НОМЕР АНСАМБЛЯ | CNN 1 | CNN2 | CNN3 | CNN 4 | DICE (%) |
|----------------|-------|-----------------------|----------------------|------------------------|----------|
| 1 | UNet | Cascade networks | DEEPM EDIC (T1) | Multi-class WNET | 82,13 |
| 2 | UNet | Cascade networks+ TTA | DEEPM EDIC (T1 + T2) | Multi-class WNET + TTA | 90,78 |
| 3 | WNET | Cascade networks | DEEPM EDIC (T1 + T2) | 3D UNet | 86,34 |
| 4 | WNET | Cascade networks+ TTA | DEEPM EDIC (T1) | 3D UNet + TTA | 80,43 |

Експериментально встановлено, що завдання сегментації найкраще виконує ансамбль 2. Це обумовлено специфікою CNN3 та варіацією форм CNN4. Об'єднувач з TTA - це застосування методу аугментації даних [25] при формуванні прогнозів на

останньому етапі при тестуванні на відкладеній виборці. Якщо нейронна мережа була навчена на змінених і спотворених даних, то при прогнозуванні можна спробувати показувати нейромережі різні варіанти одного і того ж самого зображення, а потім усереднити їх.

В наступних дослідках плануються провести інші експерименти з варіаціями нейронних мереж, наприклад, зі збільшенням числа епох і розміру навчальної вибірки (для чого необхідно значно більше пам'яті або з застосуванням RESNET-блоків замість згорнутих нейронних мереж. Іншим напрямом розвитку використання комбінації нейронних мереж для сегментації зображень є багатократний стекінг мереж, який ефективно зарекомендував себе в сегментації МРТ і КТ зображень.

VII. ВИСНОВКИ

У даній роботі запропонований алгоритм сегментації пухлин головного мозку на зображеннях МРТ, що реалізований на основі декількох ансамблів нейронних мереж. При ітерації алгоритму обчислення використовувались виходи базових нейронних мереж як вхідні данні для нової тренованої нейронної мережі, яка в подальшому виступає об'єднувачем для того, щоб відрізнити рубцеву тканину від клітин пухлини. Даний підхід має складний узагальнюючий характер, але, таким чином, вдається підвищити якість сегментації пухлини комбінацією нейронних мереж. Найкраще впорався нейромережевий ансамбль, який складається з таких нейромереж як UNet, Cascade networks + TTA, DEERMEDIC (T1 + T2) і Multi-class WNET + TTA, показавши перспективу розвитку стекінга у цій області.

ПЕРЕЛІК ПОСИЛАНЬ

- [1] Vasseur F., Doyle S., Dojat M., Forbes F. Fully automatic brain tumour segmentation from multiple MR sequences using hidden markov fields and variational EM. // In: Procs. NCI-MICCAI BRATS. - 2013. - pp. 18-22.
- [2] M Jorge Cardoso, Carole H Sudre, Marc Modat, Sebastien Ourselin Template-Based Multimodal Joint Generative Model of Brain Data. // Information processing in medical imaging. Springer International Publishing. - 2015. - Vol. 24. - pp. 17-29.
- [3] Lee C.h., Schmidt M., Murtha A. Segmenting brain tumors with conditional random fields and support vector machines. // CVBIA. - 2005. - pp. 469-478.
- [4] Bharath H.N., Coleman S., Sima D.M., S. Van Huffel. Tumor Segmentation from Multimodal MRI Using Random Forest with Superpixel and Tensor Based Feature Extraction. // International MICCAI Brainlesion Workshop.— 2017. — pp. 463–473.
- [5] Hansen L.K., Salamon P. Neural network ensembles. // IEEE Transactions on Pattern Analysis and Machine Intelligence.— 1990. — Vol. 12(10). — pp. 993–1001.
- [6] Menze B.H., Jakab A., Bauer S., Kalpathy-Cramer J., Farahani K., Kirby J., Burren Y., Porz N., Slotboom J., Wiest R., Lanczi L., Gerstner E., Weber M.A., Arbel T., Avants B.B., Ayache N., Buendia P., Collins D.L., Cordier N., Corso J.J., Criminisi A., Das T., Delingette H., Demiralp C., Durst C.R., Dojat M., Doyle S., Festa J., Forbes F., Geremia E., Glocker B., Golland P., Guo X., Hamamci A., Iftekaruddin K.M., Jena R., John N.M., Konukoglu E., Lashkari D., Mariz J.A., Meier R., Pereira S., Precup D., Price S.J., Raviv T.R., Reza S.M., Ryan M., Sarikaya D., Schwartz L., Shin H.C., Shotton J., Silva C.A., Sousa N., Subbanna N.K., Szekely G., Taylor T.J., Thomas O.M., Tustison N.J., Unal G., Vasseur F., Wintermark M., Ye D.H., Zhao S., Zhao B., Zikic D., Prastawa M., Reyes M., Van Leemput K. The multimodal brain tumor image segmentation benchmark (BRATS). // TMI 34(10)— 1993–2024 (2015).
- [7] Bakas S et al. Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features. // Nature Scientific Data.— 2017.
- [8] Jarrett K., Kavukcuoglu K., Ranzato M., LeCun Y. What is the best multi-stage architecture for object recognition? // 2009 IEEE 12th International Conference on Computer Vision.— 2009. — pp. 2146–2153.
- [9] Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D.G., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., Wicke, M., Yu, Y., Zheng, X., Brain, G.: TensorFlow: A system for large-scale machine learning. In: USENIX Symposium on Operating Systems Design and Implementation. pp. 265–284 (2016).
- [10] Abdulkadir, A., Lienkamp, S.S., Brox, T., Ronneberger, O.: 3D U-Net: Learning dense volumetric segmentation from sparse annotation. In: International Conference on Medical Image Computing and Computer-Assisted Intervention. pp. 424–432 (2016).
- [11] Wang, G., Li, W., Ourselin, S., Vercauteren, T.: Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks. In: Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries, pp. 178–190. Springer International Publishing (2018).
- [12] Gibson, E., Li, W., Sudre, C., Fidon, L., Shakir, D.I., Wang, G., Eaton-Rosen, Z., Gray, R., Doel, T., Hu, Y., Whyntie, T., Nachev, P., Modat, M., Barratt, D.C., Ourselin, S., Cardoso, M.J., Vercauteren, T.: NiftyNet: A deep-learning platform for medical imaging. Computer Methods and Programs in Biomedicine 158, pp. 113–122 (2018).
- [13] Kingma, D.P., Ba, J.L.: Adam: A method for stochastic optimization. In: International Conference on Learning Representations (2015).
- [14] Milletari, F., Navab, N., Ahmadi, S.A.: V-Net: Fully convolutional neural networks for volumetric medical image segmentation. In: International Conference on 3D Vision. pp. 565–571 (2016).
- [15] Kamnitsas K., Ledig C., Newcombe V.F.J., Simpson J.P., Kane A.D., Menon D.K., Rueckert D., Glocker B. Efficient multi-scale 3D CNN with fully connected CRF for

accurate brain lesion segmentation. // Medical Image Analysis.— 2017. — Vol. 36. — pp. 61–78 .

[16] Wang G., Li W., Ourselin S., Vercauteren T. Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks. // Proc. Multi-modal Brain Tumor Segmentation (BRATS) Challenge 2017 - MICCAI workshop.— arXiv:1709.00382. — 2017.

[17] Günter Klambauer, Thomas Unterthiner, Andreas Mayr, Sepp Hochreiter. Self-Normalizing Neural Networks.// arXiv:1706.02515. — 2017.

[18] P. K. Sahoo, S. Soltani, A. K. C. Wong, and Y. C. Chen, "A survey of thresholding techniques", CVGIP, vol. 41, no. 2, pp. 233-260, Feb.1988.

[19] W. K. Pratt, "Digital Image Processing", New York: Wiley, 1991, pp. 597-625.

[20] T. Pavlidis and Y. T. Liow, "Integrating region growing and edge detection", IEEE Trans. Pattern Anal. Machine Intell., vol. 12, no. 3, pp. 225-233, Mar. 1990.

[21] R. M. Haralick and I. Dinstein, "A spatial clustering procedure for multiimage data", IEEE Trans. Circuits Syst., vol. 22, no. 5, pp. 440-450, May 1975.

[22] R. C. Dubes, A. K. Jain, S. G. Nadabar, and C. C. Chen, "MRF model based algorithms for image segmentation" in Proc. Int. Cons Pattern Recognition, 1990, pp. 808-814.

[23] K. S. Fu and J. K. Mu, "A survey on image segmentation", Pattern Recognition, vol. 13, no. 1, pp. 3-16, Feb. 1981.

[24] Taha A.A., Hanbury A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. // BMC Medical Imaging.— 2015.

[25] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 770–778, 2016.

УДК 004.93

АЛГОРИТМ СЕГМЕНТАЦИИ НОВООБРАЗОВАННЫХ ОПУХОЛЕЙ НА МРТ ИЗОБРАЖЕНИИ ГОЛОВНОГО МОЗГА С ПОМОЩЬЮ КОМБИНАЦИИ НЕЙРОННЫХ СЕТЕЙ

Помпа К. В.,

kostiantynpompa@gmail.com,

Максименко В. Б., д.м.н., проф.

maksymenko.vitaliy@gmail.com

Факультет Биомедицинской Инженерии

Национальный технический университет Украины

"Киевский политехнический институт им. Игоря Сикорского"

Киев, Украина

Реферат – Предложен алгоритм сегментации опухолей головного мозга на изображениях МРТ, который реализован на основе нескольких ансамблей нейронных сетей. При интерации алгоритма вычисления используются выходы базовых нейронных сетей как входные данные для новой тренированной нейронной сети, которая в дальнейшем выступает в качестве объединителя для того, чтобы отличить рубцовую ткань или не пораженную ткань от клеток опухоли. Данный подход имеет сложный обобщающий характер, но, таким образом, удается повысить качество сегментации опухоли комбинацией нейронных сетей. Особенность алгоритма заключается в том, что индивидуальный результат каждого классификатора определяется на основе натренированных ранее моделей, потом вексель классифицируется, как часть опухоли, если хоть один из классификаторов определяет его как опухоль. Далее результат сегментации базовых классификаторов попадает на вход уже наученного мета-классификатора, который принимает окончательное решение по принадлежности векселя на изображении к клеткам опухоли.

Ключевые слова – сегментация изображения, нейронные сети, нейросетевые ансамбли, комбинация нейронных сетей, опухоли головного мозга, МРТ изображения.

ALGORITHM OF SEGMENTATION OF RELAPSED BRAIN TUMORS ON MRI IMAGE WITH NEURAL NETWORK COMBINATIONS ASSISTANCE

K. Pompa,

kostiantynpompa@gmail.com

V. Maksymenko, Doctor of Medical Sciences, Professor

maksymenko.vitaliy@gmail.com

Faculty of Biomedical Engineering

The National Technical University of Ukraine

"Igor Sikorsky Kyiv Polytechnic Institute"

Kyiv, Ukraine

Abstract – The algorithm of segmentation of brain tumors in MRI images is proposed. In the iteration of the computation algorithm, the outputs of the base neural networks are used as input data for a new trained neural network, which in the future serves as a unifier in order to distinguish scar tissue or non-affected tissue from tumor cells. This approach has a complex generalization, but, thus, it is possible to improve the quality of segmentation of the tumor by a combination of neural networks. The components of the algorithm are basic classifiers that will extract complex functions of the regularities (often implicit) from the data stream, and the unifier will become a classifier that aggregates these functions. At the aggregation level, the data is derived from the classifiers, and the aggregation of the single output. When iterating the computation algorithm, the outputs of the basic classifiers are used as input data for the new trained neural network, which later acts as a unifier. The key idea of the algorithm is that the individual result for each classifier is determined based on the models previously trained, then the voxel is classified as part of the tumor if at least one of the classifiers determines it as a tumor. Further, the result of segmentation of the basic classifiers falls on the input of the already trained meta-classifier, which makes the final decision regarding the voxel's belonging to the image to the tumor cells. In this case, a special algorithm is used. The pixel algorithm proposes to classify pixels in adjacent areas based on gray levels. This method uses local information - the values of the gray levels of adjacent pixels, or, global information - the total distribution of the gray levels of adjacent pixels. The gray levels reflect the intensity of the light in each pixel. At the level of input data and manipulations with them there is an input to the input of the neural network for training.

Keywords – image segmentation, neural networks, neural network ensembles, combination of neural networks, brain tumors, MRI images.