

СЕГМЕНТАЦІЯ ТУБЕРКУЛЬОЗНИХ УРАЖЕНЬ ЛЕГЕНЬ НА ЗОБРАЖЕННЯХ КОМП'ЮТЕРНОЇ ТОМОГРАФІЇ

Н.С. Ворончук¹, К.С. Бовсунівська^{1*}, О.Б. Давидько¹, М.І. Линник²,
О.В. Матвійчук¹, А.В. Павлов³, Є.А. Настенко¹

¹КПІ ім. Ігоря Сікорського, Київ, Україна

²ДУ “Національний інститут фізіотерапії і пульмонології ім. Ф.Г. Яновського НАМН України”, Київ, Україна

³Міжнародний науково-навчальний центр інформаційних технологій та систем НАН і МОН України, Київ, Україна

*Corresponding author: bmk-bks-fbmi@iill.kpi.ua

Received 16 May 2021; Accepted 14 June 2021

Проблематика. Туберкульоз – це хронічне захворювання легень, яке виникає через бактеріальну інфекцію та входить до десятки основних причин смертності людини. Як частина системи автоматизованої діагностики виявлення туберкульозних уражень на комп'ютерних томограмах легень у автоматичному режимі є актуальною задачею.

Мета. Вирішення проблеми сегментації уражених туберкульозом ділянок легень на комп'ютерних томограмах за допомогою цифрової обробки зображень на основі U-мереж.

Методика реалізації. Дані для навчання мережі надано фахівцями ДУ “Національний інститут фізіотерапії і пульмонології ім. Ф.Г. Яновського НАМН України”. Сегментація зображень виконана засобами штучного інтелекту за допомогою згорткової нейронної мережі U-Net, яка була розроблена для задач медичної сегментації. Розглянуто три версії U-Net мереж із різними параметрами. Особливістю U-Net є відсутність повнозв'язних шарів. Ця мережа є прикладом архітектури кодувальника-декодувальника, що показує високі результати в задачах семантичної сегментації зображень. У двох останніх моделях застосована техніка ранньої зупинки навчання, яка дає можливість уникнути ефекту перенавчання мережі. Кількість епох навчання задається із запасом, при цьому процес навчання параметрів мережі зупиняється, шойно продуктивність моделі припиняє поліпшуватися на тестовому наборі даних.

Результати. Набір даних був розділений на 320 зразків (80 %) для навчання, 40 зразків (10 %) для тестування та 40 зразків (10 %) для екзамену. Ефективність розроблених моделей була оцінена за параметрами: точність, чутливість, коефіцієнт кореляції Метьюза. Кінцева модель забезпечує на екзамені високі показники продуктивності, такі як точність 0,82, чутливість 0,75, коефіцієнт кореляції Метьюза 78 %.

Висновки. Проведені дослідження при застосуванні мережі U-Net дали змогу одержати високі результати для сегментації туберкульозних уражень на зображеннях комп'ютерної томографії. Пропонувана мережа буде застосована при подальшій розробці діагностичних систем при захворюванні на туберкульоз.

Ключові слова: сегментація патологій; нейронна мережа; туберкульоз; U-Net; штучний інтелект; тренування мереж.

Вступ

Туберкульоз – одна з потенційно смертельних хвороб людства, і необхідною умовою успішного лікування є виявлення його на ранній стадії. Доступні кілька методів дослідження легень, але рентгенограми грудної клітини є одним із найважливіших інструментів скринінгу для виявлення патологій легень [1, 2]. В основному прояви туберкульозу можна виявити за допомогою рентгенографії, проте кількість кваліфікованих радіологів для точної інтерпретації рентгенографії обмежена і вони недоступні для хворих у периферійних регіонах [3].

Тому однією із сучасних й актуальних тенденцій розвитку технологій у медицині є цифрова обробка зображень. Порівняно з ручним, автоматичні методи сегментації патологій суттєво більш ефективні: їх точність і швидкість вищі. Методи та засоби автоматичної обробки зображень швидко розвиваються, що дає змогу створювати нові підходи до вирішення проблем цього типу і покращувати результати існуючих технологій. З'явилася можливість використовувати обчислювальні потужності на порядки більші, ніж 10–15 років тому. Оскільки збільшується і обсяг інформації, поданої у цифровому вигляді, для діагностики захворювань, лікування

яких важливе на ранніх стадіях, то актуальності набули різноманітні методи комп'ютерної обробки, перетворення й аналізу медичних зображень [4, 5].

Останніми роками було опубліковано чимало досліджень у галузі комп'ютерної сегментації, проте однозначно правильних і точних методів сегментації патологій на медичних зображеннях досі не було розроблено. Кожна конкретна проблема такого типу потребує індивідуального підходу, і це свідчить про необхідність розвитку методів дослідження зображень із патологіями.

У праці [6] представлена система комп'ютерної діагностики, що базується на архітектурах Alexnet і VGGNet для класифікації рентгеновських знімків на позитивні та негативні класи. Результати роботи свідчать про деяку перевагу архітектури VGGNet, у рамках якої була розроблена модель із точністю, вищою на 1,2%, що становила 81,6%. Проте автор підкреслює, що можна було досягнути більш точного результату, збільшивши кількість зразків для навчання мережі.

Модель ConVnet розглядалася в [7] для класифікації різних проявів інфекційного захворювання. Була отримана точність 85,6%, що є досить високим результатом при 4701 зразку зображення, 4248 із яких були відзначені як патологія, а решта – як норма.

Підхід, що наведений у праці [8], базується на глибокому навчанні; результатом є класифікатор рентгенограм грудної клітини. Структура нейронної мережі формується із семи згорткових шарів і трьох шарів, що використовуються для класифікації. Також було застосовано порівняння оптимізаторів різноманітності.

За результатами аналізу розглянутих робіт можна зробити висновок, що варіативність і кількість шляхів удосконалення систем, які розв'язують задачі, аналогічні виявленню уражень від туберкульозу легень, становить широку область для досліджень. Задачею нашої роботи є підвищення точності та ефективності сегментації туберкульозних уражень легень на знімках комп'ютерної томографії (КТ).

Матеріали і методи

У роботі використовувався набір даних, що являє собою 15 серій знімків комп'ютерної томографії легень у форматі NIfTI – Neuroimaging Informatics Technology Initiative. Оскільки NIfTI передбачає відображення даних у форматі

3D-моделі, то для їх обробки за допомогою нейронної мережі було виділено 400 знімків аксіального вигляду і відповідний набір даних масок легень, що містять аномальні зразки. Всі зразки мають розмір 646×431 пікселів, збережених у форматі PNG, як показано на рис. 1.




Рисунок 1: Зразок аксіального зрізу комп'ютерної томографії грудної клітини

Зміна розміру. Для встановлення відповідності розміру зображення (в пікселях) вибраному розміру вхідної матриці мережі першим кроком попередньої обробки зображень було зменшення КТ-зображень до розміру 256×256 пікселів. Процедура реалізована за допомогою бібліотеки програмування OpenCV, що містить програмні засоби комп'ютерного зору для застосування в реальному часі (рис. 2).




Рисунок 2: Зміна розміру зображень: (а) оригінальне зображення (розмір 646×431 пікселів); (б) змінене зображення (розмір 256×256 пікселів)

Сегментація. У літературі доступний опис декількох варіантів моделей сегментації на основі U-мереж. На рис. 3 показана архітектура мережі U-Net [4]. Архітектура мережі являє собою згорткову мережу без участі повнозв'язних шарів, модифіковану таким чином, що, оброблюючи меншу кількість зображень для навчання, вона досягає більш точної сегментації. Мережа містить шлях стискання та шлях розширення. На кожному кроці стискання ми

подвоюємо кількість каналів карт характеристик, зменшуючи вдвічі їх розмір і навпаки на шляху розширення.




Рисунок 3: Схема архітектури U-Net [4]

U-Net складається зі згорткових шарів, між якими застосовуються MaxPooling шари. Для кожного згорткового шару застосовується функція активації ReLU (rectified linear unit). Крім того, в цій мережі можна виділити дві основні складові частини: кодувальник і декодувальник.

Кодувальник складається з 4-х блоків стиснення. Кожен блок отримує вхідні дані, застосовує два згорткових шари ReLU 3×3, а потім реалізує максимальне об'єднання 2×2. Кількість карт функцій збільшується вдвічі на кожному рівні об'єднання. Шар вузького місця використовує два шари 3×3 Conv і 2×2 up згортковий шар. Декодувальник складається з кількох блоків розширення, кожен із яких передає вхідні дані двом шарам 3×3 Conv і шару, що підвищує дискретизацію 2×2 і вдвічі зменшує кількість каналів функцій. Він також включає конкатенацію з відповідним чином обрізаною картою об'єктів зі шляху скорочення. Зрештою, шар 1×1 Conv використовується для того, щоб кількість карт об'єктів була такою самою, як кількість сегментів, що наявні у вихідних даних.

Функція втрат: U-net використовує функцію втрат для кожного пікселя зображення. Це допомагає легко ідентифікувати окремі осередки в карті сегментації. Softmax застосовується до кожного пікселя, після чого розраховується функція втрат. Це перетворює проблему сегментації на проблему класифікації, коли нам потрібно віднести кожен піксель до одного з класів [9].

Шари згортки. Шари згортки є фундаментальними компонентами архітектури згорткової нейронної мережі CNN – Convolutional Neural Network, що формують ознаки. Перетворення зазвичай складаються з комбінацій лінійних і нелінійних операцій, тобто операцій згортки і функцій активації [10].

Згортка – це спеціалізований тип лінійної операції, який використовується для вилучення ознак, коли невеликий масив чисел (ядро) застосовується до входу, що являє собою масив чисел, званий тензором. Поелементний добуток між кожним елементом ядра і вхідним тензором обчислюється в кожному місці тензора і підсумовується для отримання вихідного значення у відповідному положенні вихідного тензора так звану картою ознак (рис. 4). Ця процедура повторюється із застосуванням кількох ядер для формування довільної кількості карт ознак, які представляють різні характеристики вхідних тензорів. Двома ключовими гіперпараметрами, що визначають операцію згортки, є розмір і кількість ядер. Перший (розмір ядра) може бути встановлено 3×3, або 5×5, або 7×7. Другий (кількість ядер) є довільним і визначає глибину вихідних карт функцій [11].




Рисунок 4: Формування згорткового шару

Блок кодувальника. Блок кодувальника діє як екстрактор ознак і досліджує абстрактне уявлення вхідного зображення через послідовність блоків кодувальника. Функція активації ReLU привносить у мережу нелінійність, яка допомагає краще узагальнювати дані навчання. Вихід ReLU діє як пропускне з'єднання для відповідного блоку декодувальника. В нашому випадку функція кодувальника приймає два параметри: це карти функцій із попереднього блоку та число фільтрів, що відноситься до кількості вихідних каналів функцій. Блок кодувальника приймає вхідний сигнал розміру 128×128×32 з кількістю фільтрів 64, і повертає вихідний сигнал $x = 128 \times 128 \times 64$ і $z = 64 \times 64 \times 64$ [5].

Мережа декодувальника. Мережа декодувальника використовується для абстрактного формування і генерації відповідної маски семантичної сегментації. Функція декодувальника реалізує транспоновану згортку 2×2 . Потім результат об'єднується з відповідною картою функцій пропуску з'єднання з блоку кодувальника. Ці з'єднання є функціями з більш ранніх шарів, які іноді губляться через глибину мережі. Після цього використовуються дві згортки 3×3 , де за кожною згорткою слідує функція активації ReLU. Декодувальник мережі приймає три параметри: це вхідні дані, що являють собою карти функцій із попереднього блоку, карти функцій із блоку кодувальника, що отримуються через з'єднання пропуску, та кількість вихідних каналів функцій. Якщо розмір вхідних даних дорівнює $16 \times 16 \times 32$, а кількість фільтрів дорівнює 64, то на виході маємо транспоновану згортку $32 \times 32 \times 64$.

Гіперпараметри для навчання. Гіперпараметри Convolutional Neural Network – це основний засіб для оптимізації продуктивності мережі, оскільки вони безпосередньо контролюють процес навчання. Наприклад, якщо швидкість навчання занадто низька, мережа може втратити важливі деталі в даних. За великого числа епох навчання може наступити втрата узагальнюючих властивостей мережі. За занадто високої швидкості навчання та швидкої збіжності моделі можуть бути одержані низькі показники якості класифікації. Отже, існує необхідність в оптимізації гіперпараметрів Convolutional Neural Network для належного навчання і оптимізації результатів продуктивності. Виходячи з досвіду навчання першої моделі, ми побудували дві моделі, що мали відкореговані параметри (табл. 1).

Таблиця 1: Гіперпараметри моделей

Гіперпараметри	Модель № 1	Модель № 2	Модель № 3
Batch size	8	10	10
Epochs	20	32	40
Activation function	ReLU	ReLU	ReLU
Optimizer	Adam	Adam	Adam
Loss function	Binary Cross-entropy	Binary Cross-entropy	Binary Cross-entropy
Patience	–	4	3

Кількість епох (Epochs) навчання мережі – це кількість повних проходів через навчальний набір даних. Для кількості епох можна задати

цілочислове значення від одиниці до нескінченності. Цей параметр не має однозначного найкращого значення. Для кожної задачі воно своє.

Функція активації (Activation function) використовується для виконання складних обчислень у прихованих шарах і подальшої передачі результату на вихідний рівень. У всіх трьох моделях використана функція випрямленого лінійного блоку – ReLU.

Функція втрат (Loss function) – важливий компонент нейронних мереж. Втрата – це помилка прогнозу нейронної мережі. Функція втрат задає шлях обчислення відносної міри втрати мережі як залежності від параметрів мережі (вагів, деяких параметрів функцій активації). Часткові похідні функції за вагами застосовуються для адаптації ваг у напрямі антиградієнта.

Розмір пакета (Batch size) – визначає кількість зразків, що оброблюються перед оновленням моделі нейронної мережі. Розмір пакета може змінюватися від одиниці до кількості зразків у навчальному наборі даних. Для нашого дослідження, зважаючи на наявні апаратні засоби, було вибрано 10 зразків у пакеті для 4 і 3-х пацієнтів відповідно.

Занадто велика кількість епох може призвести до перенавчання мережі, а занадто мала кількість епох призводить до низької ефективності моделі. Рання зупинка – це техніка, яка дає змогу вказати довільно велику кількість навчальних епох і припинити навчання, щойно продуктивність моделі перестане покращуватись на тестовому наборі даних. Цей метод був доданий у двох останніх моделях.

Результати

Результати роботи моделей показано на рис. 5–7. З рис. 5 видно, що модель № 1 U-net не здатна сегментувати області туберкульозних уражень, на відміну від наступних двох моделей, результат роботи яких показано на рис. 6, 7.

Набір даних був розділений на 320 (80 %) для навчання, 40 (10 %) для тестування та 40 (10 %) для екзаменаційної вибірки. Розбиття на вибірки реалізовано випадковим чином із метою одержання об'єктивних оцінок якості класифікації. Зразки в тестовому наборі не беруть участі в навчанні параметрів мережі, і модель їх не “бачить” до моменту оцінки продуктивності в кінці кожного поточного періоду навчання. Для вибору оптимального набору параметрів мережі навчання припиняється, щойно оцінка продуктивності на тесті перестане покращуватись.




Рисунок 5: Результат роботи моделі № 1




Рисунок 6: Результат роботи моделі № 2




Рисунок 7: Результат роботи моделі № 3

Показники продуктивності мережі на іспиті застосовуються як об'єктивні оцінки якості отриманої моделі. Потім вибирається модель із кращими показниками на тестовій і екзамінаційній вибірках. Якість моделей характеризується з використанням показників продуктивності *Accuracy* (загальна точність класифікатора), *Recall* (повнота чи чутливість), *Precision* (позитивна точність класифікатора) та коефіцієнта кореляції Метьюза. Рівняння показників продуктивності наведені в табл. 2.

Таблиця 2: Показники продуктивності моделей

Метрика	Модель № 1	Модель № 2	Модель № 3
<i>Accuracy</i>	0,29	0,99	0,97
<i>Precision</i>	0,24	0,85	0,82
<i>Recall</i>	0,89	0,67	0,75
<i>MCC</i>	0,159	0,759	0,778
<i>Loss</i>	0,18	0,091	0,087

Обговорення

При розрахунку метрик ефективності застосовуються дані матриці помилок. Вона відображає бінарний процес класифікації. Відомий вигляд матриці представлений в табл. 3.

Таблиця 3: Матриця помилок

Передбачуване значення	Фактичне значення	
	Positive	Negative
	Positive	TP
Negative	FN	TN

При класифікації набору даних існують чотири комбінації фактичних категорій і категорій, визначених класифікатором:

- *TP* (дійсно позитивний): кількість результатів, що правильно прогнозовані як фактичні позитивні.
- *FP* (хибно позитивний): кількість результатів, що неправильно прогнозують позитивний результат; тут фактично негативні значення прогнозуються як позитивні.
- *FN* (помилково негативний): кількість результатів, у яких позитивні значення прогнозуються як негативні.
- *TN* (дійсно негативний): кількість результатів, що правильно прогнозовані як фактичні негативні.

Ці категорії застосовуються в розрахунку більш складних показників класифікації, таких як точність, позитивна точність, чутливість класифікатора, коефіцієнт кореляції Метьюза.

Параметр *Precision* – *позитивна точність класифікатора* – демонструє, наскільки точна модель на об'єктах, що були визнані класифікатором як позитивні (скільки з них дійсно позитивні). Цей параметр обчислюється за формулою

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

Recall – *чутливість (повнота)*, характеризує точність класифікатора на позитивних об'єктах вибірки, розраховується таким чином:

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

Accuracy – *загальна точність класифікатора*, виявляє частку правильних відповідей алгоритму сумарно в обох класах:

$$Accuracy = \frac{TP + TN}{TN + FN + TP + FP}$$

Таблиця 4: Порівняння результативності моделей

Модель	Параметр				
	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>AUC</i>	<i>MCC</i>
Модель № 1	0,29	0,24	0,89	0,64	0,159
Модель № 2	0,99	0,85	0,67	0,93	0,759
Модель № 3	0,97	0,82	0,75	0,97	0,778
Average [15]	0,767	0,824	–	–	–
Gradient Vector Flow[12]	–	0,81	–	–	–
GoogLeNet [14]	0,887	–	–	0,89	–
GoogLeNet[16]	0,760	–	–	0,834	–
Gaussian model-based [17]	0,75	0,81	0,69	–	–
VGG-16 [18]	0,88	0,87	0,89	0,94	0,76
MobileNet-V2 [18]	0,86	0,91	0,87	0,84	0,72

Loss – це помилка, що оцінюється під час навчання моделі: чим менше значення, тим краще модель відповідає даним. Втрати розраховуються на основі навчальної та тестової вибірок. Для оцінки поточних моделей використовувалась двійкова перехресна ентропія:

$$H_{y'}(y) := -\sum_i y'_i \log(y_i),$$

де y_i – прогнозоване значення ймовірності для класу i , а y' – справжня ймовірність для цього класу.

Коефіцієнт кореляції Метьюза (MCC – Matthews correlation coefficient) забезпечує найбільш повний та інформативний аналіз побудованої моделі. Він фактично вимірює кореляцію справжніх класів із передбаченими мітками. На відміну від інших показників, описаних вище, *MCC* враховує всі аспекти матриці помилок:

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP) \cdot (TP + FN) \cdot (TN + FP) \cdot (TN + FN)}}$$

Показник знаходиться в інтервалі $[-1, +1]$ з екстремальними значеннями -1 і $+1$, що досягаються в разі повної неправильної класифікації та ідеальної класифікації відповідно. В роботі ми віддаємо пріоритет метриці *MCC*, оскільки вона збалансовано характеризує класифікацію як негативних, так і позитивних зразків. *MCC = 0,778* виявився кращим у моделі № 3. Досить високі результати моделі були отримані завдяки налаштуванню гіперпараметрів навчання нейронної мережі. Показники моделей № 1, 2, 3 зведено в табл. 4 із результатами робіт [12–18], що розв'язували задачі визначення туберкульозних уражень легень на КТ і рентген-знімках на

основі мереж різних видів і гібридних схем. Заповнені комірки таблиці відповідають характеристикам, що розраховувались у відповідних роботах. Порівняння результатів свідчить про те, що моделі № 2 і 3 є цілком конкурентними на нинішньому етапі розвитку автоматичних систем сегментації туберкульозних уражень.

Досягнуті результати моделей № 1, 2 із точністю відповідно 0,85 і 0,82 демонструють ефективність використання U-Net подібних архітектур у задачах семантичної сегментації. Шляхи покращення результатів можуть бути досліджені при використанні гібридних схем нейромереж, а також за допомогою оптимізації більшої кількості гіперпараметрів, зокрема learning rate. Крім того, в майбутніх дослідженнях буде доцільно застосувати техніки аугментації даних для розширення тестової вибірки та покращення якості процесу навчання.

Висновки

У роботі були представлені результати побудови, навчання та застосування трьох різних мереж Convolutional Neural Network для виявлення патологічних областей, що являють собою туберкульозні ураження на знімках комп'ютерної томографії легень. Застосування мережі U-Net для розробки моделей класифікації показало їх конкурентні можливості для сегментації туберкульозних уражень. Пропонована фінальна модель забезпечує високі показники продуктивності, такі як точність – 0,82, чутливість – 0,75, коефіцієнт кореляції Метьюза – 78 %.

Подальше дослідження проблеми буде зосереджено на розширенні функціоналу системи, удосконаленні архітектури мережі, класифікації стадій інфекційного захворювання.

References

- [1] Tuberculosis prevalence surveys: a handbook. Geneva: World Health Organization; 2011.
- [2] Chest radiography in tuberculosis detection: summary of current WHO recommendations and guidance on programmatic approaches. Geneva: World Health Organization; 2016. 39 p.
- [3] Lakhani P, Sundaram B. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology*. 2017;284(2):574-82. DOI: 10.1148/radiol.2017162326
- [4] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation. arXiv [Preprint] 2015. arXiv:1505.04597.
- [5] Bondina MM, Kalmychikov AS, Kriventsov VE. Comparative analysis of algorithms filtration of medical images. *Herald of the National Technical University KhPI Subject Issue Information Science and Modelling*. 2012;38:14-25.
- [6] Hwang S, Kim HE, Jeong J, Kim HJ. A novel approach for tuberculosis screening based on deep convolutional neural networks. In: *Proceedings of SPIE 9785, Medical Imaging 2016 Computer-Aided Diagnosis*; 2016 Mar 24. DOI: 10.1117/12.2216198
- [7] Liu C, Cao Y, Alcantara M, Liu B, Brunette M, Peinado J, et al. TX-CNN: detecting tuberculosis in chest X-ray images using convolutional neural network. In: *IEEE International Conference on Image Processing*; 2017. p. 2314-8. DOI: 10.1109/ICIP.2017.8296695
- [8] Hooda R, Sofat S, Kaur S, Mittal A, Meriaudeau F. Deep-learning: a potential method for tuberculosis detection using chest radiography. In: *IEEE International Conference on Signal and Image Processing Applications*; 2017; p. 497-502. DOI: 10.1109/ICSIPA.2017.8120663
- [9] Pedrazzoli D, Lalli M, Boccia D, Houben R, Kranzer K. Can tuberculosis patients in resource-constrained settings afford chest radiography? *Eur Respir J*. 2017;49(3):1601877. DOI: 10.1183/13993003.01877-2016
- [10] Nair V, Hinton GE. Rectified linear units improve restricted Boltzmann machines. In: *Proceedings of the 27th International Conference on Machine Learning*; 2010.
- [11] Ramachandran P, Zoph B, Le QV. Searching for activation functions. arXiv [Preprint] 2017. arXiv:1710.05941.
- [12] Swanly VE, Selvam L, Kumar PM, Renjith JA, Arunachalam M, Shunmuganathan KL. Smart spotting of pulmonary TB cavities using CT images. *Comput Math Methods Med*. 2013;2013:864854. DOI: 10.1155/2013/864854
- [13] Mossa AA, Eris H, Zevik U. Ensemble of deep learning models for automatic tuberculosis diagnosis using chest CT scans: contribution to the ImageCLEF-2020 challenges. In: *Working notes of conference and labs of the evaluation forum*; 2020 Sep 22-25; Thessaloniki.
- [14] Kalinovsky A, Liauchuk V, Tarasau A. Lesion detection in ct images using deep learning semantic segmentation technique. *Int Arch Photogramm Remote Sens Spatial Inf Sci*. 2017;XLII-2/W4;13-7. DOI: 10.5194/isprs-archives-XLII-2-W4-13-2017
- [15] Ayaz M, Shaukat F, Raja G. Ensemble learning based automatic detection of tuberculosis in chest X-ray images using hybrid feature descriptors. *Phys Eng Sci Med*. 2021;44(1):183-94. DOI: 10.1007/s13246-020-00966-0
- [16] Lopes UK, Valiati JF. Pre-trained convolutional neural networks as feature extractors for tuberculosis detection. *Comput Biol Med*. 2017;89(1):135-43. DOI: 10.1016/j.compbiomed.2017.08.001
- [17] Xu T, Cheng I, Long R, Mandal M. Novel coarse-to-fine dual scale technique for tuberculosis cavity detection in chest radiographs. *EURASIP J Image Video Process*. 2013;2013(1). DOI: 10.1186/1687-5281-2013-3
- [18] Rajaraman S, Folio LR, Dimperio J, Alderson PO, Antani SK. Improved semantic segmentation of tuberculosis-consistent findings in chest X-rays using augmented training of modality-specific U-Net models with weak localizations. *Diagnostics (Basel)*. 2021;11(4):616. DOI: 10.3390/diagnostics11040616

Н.С. Ворончук¹, К.С. Бовсуновская^{1*}, О.Б. Давидько¹, М.И. Линник², О.В. Матвийчук¹, А.В. Павлов³, Е.А. Настенко¹

¹КПИ им. Игоря Сикорского, Киев, Украина

²ГУ “Национальный институт фтизиатрии и пульмонологии им. Ф.Г. Яновского НАН Украины”, Киев, Украина

³Международный научно-учебный центр информационных технологий и систем НАН Украины и МОН Украины, Киев, Украина

СЕГМЕНТАЦИЯ ТУБЕРКУЛЕЗНЫХ ПОРАЖЕНИЙ ЛЕГКИХ НА ИЗОБРАЖЕНИЯХ КОМПЬЮТЕРНОЙ ТОМОГРАФИИ

Проблематика. Туберкулез – это хроническое заболевание легких, возникающее из-за бактериальной инфекции и входящее в десятку основных причин смертности человека. Как часть системы автоматизированной диагностики выявление туберкулезных поражений на компьютерных томограммах легких в автоматическом режиме является актуальной задачей.

Цель. Решение проблемы сегментации пораженных участков легких на компьютерных томограммах с помощью цифровой обработки изображений на основе U-сетей.

Методика реализации. Данные для обучения сети предоставлены специалистами ГУ “Национальный институт фтизиатрии и пульмонологии им. Ф.Г. Яновского НАН Украины”. Сегментация изображений выполнена средствами искусственного интеллекта с помощью сверточной нейронной сети U-Net, которая была разработана для задач медицинской сегментации. Рассмотрены три версии U-Net сетей с различными значениями параметров. Особенностью U-Net является отсутствие полносвязных слоев. Данная сеть является примером архитектуры кодировщика-декодировщика, которая показывает высокие результаты в

задач семантической сегментации изображений. В двух последних моделях применена техника ранней остановки обучения, которая позволяет избежать эффекта переобучения сети. Количество эпох обучения задается с запасом, при этом процесс обучения параметров сети останавливается, как только производительность модели прекращает улучшаться на тестовом наборе данных.

Результаты. Набор данных был разделен на 320 образцов (80 %) для обучения, 40 образцов (10 %) для тестирования и 40 образцов (10 %) для экзамена. Эффективность разработанных моделей была оценена параметрами: точность, чувствительность, коэффициент корреляции Мэтьюза. Окончательная модель обеспечивает на экзамене высокие показатели производительности, такие как точность 0,82, чувствительность 0,75, коэффициент корреляции Мэтьюза 78 %.

Выводы. Проведенные исследования при применении сети U-Net позволили получить высокие результаты для сегментации туберкулезных поражений на изображениях компьютерной томографии. Предлагаемая сеть будет применена при дальнейшей разработке диагностических систем при заболевании туберкулезом.

Ключевые слова: сегментация патологий; нейронная сеть; туберкулез; U-Net; искусственный интеллект; тренировка сетей.

N.S. Voronchuk¹, K.S. Bovsunovska^{1*}, O.B. Davydko¹, M.I. Lynnyk², O.V. Matviichuck¹, A.V. Pavlov³, Ie.A. Nastenko¹

¹Igor Sikorsky Kyiv Polytechnic Institute, Kyiv, Ukraine

²National Institute of Phthiology and Pulmonology named after F.G. Yanovsky, NAMS of Ukraine, Kyiv, Ukraine

³International Research and Training Center for Information Technologies and Systems, NAS and MES of Ukraine, Kyiv, Ukraine

SEGMENTATION OF TUBERCULOSIS LUNGS ON COMPUTER TOMOGRAPHY IMAGES

Background. Tuberculosis is a chronic lung disease that occurs due to a bacterial infection and is one of the top ten causes of human death. As part of the automated diagnostic system, the detecting tuberculosis lesions on computed tomograms of the lungs in automatic mode is an urgent task.

Objective. We are aimed to solve the lungs segmentation tuberculosis-affected areas problem on computer tomograms using digital image processing based on U-networks.

Methods. The data for training the network were provided by the specialists of National Institute of Phthiology and Pulmonology named after F.V. Yanovsky, NAMS of Ukraine. We performed the image segmentation by applying artificial intelligence using the convolutional neural network UNet, which has been developed for medical segmentation tasks. We considered three versions of UNet networks with different parameter values. A feature of U-Net is the absence of fully connected layers. This network is an example of an encoder-decoder architecture, which shows high results in problems of semantic image segmentation. In the last two models, we applied the technique of early stopping of training which avoids the effect of overfitting the network. The number of training epochs is set with a margin, and the process of training network parameters stops as soon as the model performance stops improving on the test data set.

Results. The data set was divided into 320 samples (80%) for training, 40 samples (10%) for testing, and 40 samples (10%) for the exam. The effectiveness of the developed models was evaluated by the parameters: Precision, Recall, and Matthews correlation coefficient. The final model provides high performance on the exam, such as accuracy of 0.82, sensitivity of 0.75, Matthews correlation coefficient of 78%.

Conclusions. The conducted studies using the UNet network allowed us to obtain high results for the segmentation of tuberculosis lesions on computed tomography images. The proposed network will be used in the further development of diagnostic systems for tuberculosis.

Keywords: pathology segmentation; neural network; tuberculosis; U-Net; artificial intelligence; training networks.