

МІНІСТЕРСТВО ОСВІТИ ТА НАУКИ УКРАЇНИ
Тернопільський національний економічний університет
Факультет комп'ютерних інформаційних технологій
Кафедра комп'ютерної інженерії

Сухович Аліна Русланівна

**Синтез цитологічних зображень на основі
згорткових нейронних мереж / Synthesis of
cytological images based on convolutional neural
networks**

спеціальність:123 – Комп'ютерна інженерія
освітньо-професійна програма – Комп'ютерна інженерія

Випускна кваліфікаційна робота

Виконав студент групи КІм-21
А. Р. Сухович

Науковий керівник:
д.т.н., професор, О. М. Березький

ТЕРНОПІЛЬ - 2019

РЕЗЮМЕ

Магістерська робота на тему “ Синтез цитологічних зображень на основі згорткових нейронних мереж” на здобуття освітньо-кваліфікаційного рівня “Магістр” зі спеціальності “Комп’ютерні системи та мережі” написана обсягом 113 сторінок і містить 44 ілюстрацій, 3 таблиці, 3 додатки та 70 джерел за переліком посилань.

Метою роботи є розроблення алгоритмів синтезу цитологічних зображень на основі генеративно-змагальних мереж та проектування програмного модуля синтезу цитологічних зображень.

Методи досліджень. Для розв’язання поставлених задач у магістерській роботі використано: методи: математичного аналізу та теорії ймовірностей (для синтезу зображень); об’єктно-орієнтованого програмування (для проектування програмного модуля синтезу зображень).

Результати дослідження: алгоритми синтезу цитологічних зображень на основі генеративно-змагальних мереж, програмний модуль синтезу цитологічних зображень.

Результати роботи можуть бути використані для формування штучних баз даних цитологічних зображень при навчанні згорткових нейронних мереж, в морфології та в навчальному процесі.

Орієнтовні напрямки розвитку досліджень: розроблення окремих модулів систем автоматизованої мікроскопії; створення розподілених баз даних для зберігання штучних баз даних зображень, створення засобів телемедицини.

КЛЮЧОВІ СЛОВА: СИНТЕЗ, ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ, ЦИТОЛОГІЧНІ ЗОБРАЖЕННЯ, ПРОГРАМНИЙ МОДУЛЬ.

RESUME

Master's thesis on "Synthesis of cytological images based on convolutional neural networks" for obtaining the Master's degree in "Computer Systems and Networks" specialty is written with a volume of 113 pages and contains 44 illustrations, 3 tables, 3 applications and 70 sources by the list of links.

The purpose of the work is to develop algorithms for the synthesis of cytological images on the basis of generative-competitive networks and design a software module for the synthesis of cytological images.

Research Methods. To solve the problems in the master's thesis the following methods were used: mathematical analysis and probability theory (for image synthesis); object-oriented programming (to design an image synthesis software module).

Results of the research: algorithms and synthesis of cytological images on the basis of generative-competitive networks, software module for synthesis of cytological images.

The results of the work can be used for the formation of artificial databases of cytological images in the study of convolutional neural networks, in morphology and in the educational process.

Indicative directions of research development: development of separate modules of automated microscopy systems; creation of distributed databases for storage of artificial image databases, creation of telemedicine facilities.

KEYWORDS: SYNTHESIS, CONVERTING NEURAL NETWORKS, CYTOLOGICAL IMAGES, SOFTWARE MODULE.

ЗМІСТ

Вступ.....	9
1 Аналіз методів і алгоритмів синтезу цитологічних зображень на основі нейронних мереж.....	11
1.1 Аналіз цитологічних зображень.....	11
1.2 Аналіз архітектур штучних нейронних мереж.....	19
1.3 Аналіз програмних засобів синтезу зображень.....	32
1.4 Постановка завдання на магістерське дослідження.....	37
2 Структура синтезу зображень на основі генеративно-змагальних нейронних мереж.....	38
2.1 Структури генеративно-змагальних мережі.....	38
2.2 Структури глибоко-згорткових генеративно-змагальних мереж...	42
2.3 Застосування структур генеративно-змагальних мереж для синтезу біомедичних зображень.....	44
3 Програмна реалізація модуля синтезу зображень.....	67
3.1 Структура програмного модуля.....	67
3.2 Архітектура згорткової нейронної мережі.....	74
3.3 Порівняльний аналіз результатів класифікації зображень.....	80
Висновки.....	83
Список використаних джерел.....	84
Додаток А Світлокопії публікації.....	92
Додаток Б Текст статті “Синтез біомедичних зображень на основі генеративно-змагальних мереж”.....	98
Додаток В Довідка про використання.....	113

Умовні скорочення

1. GAN – ГЗМ (Генеративно-змагальні мережі);
2. CNN – ЗНМ (Згорткові нейронні мережі);
3. MGAN – Марківка ГЗМ;
4. cGAN (Conditional GAN) – Умовні ГЗМ;
5. cycleGAN – циклічні ГЗМ
6. AC-GAN – ГЗМ допоміжного класифікатора;
7. DCGAN (Deep Convolutional) – Глибоко-згорнуту ГЗМ;
8. Wassertain-GAN (WGAN) - Вассертейн ГЗМ;
9. Mover Earth (ME) – Пересовувач землі;
10. Least Squares (LSGAN) – Найменш-квадратична ГЗМ;
11. DAGAN (Deep De-Aliasing Generative Adversarial Networks) - Глибоке знеструмлення генеративних змагальних мереж;
12. Mobility Services Engine (MSE) - апаратний пристрій / двигун;
13. Multiple Sclerosis (MS) - 13. Розсіяний склероз;
14. SRGAN (Super Resolution Using GAN) - супер роздільна здатність за допомогою GAN;
15. SCGAN – напівукомплектований ГЗМ.
16. VGG19 (Visual Geometry Group) – Візуально-геометрична групова мережа;
17. Jensen-Shannon (JS);
18. UltraSound (US) – ультразвук;
19. CT images – Комп. Томографія;
20. 3D FCN (3D Fully Convolutional Network) – 3D повна згорткова мережа;
21. MRI images ()
22. Z – вектор шуму;
23. Domain x , y – домен x , y ;
24. D_x , D_y – два дискримінатори;

25. Patch extraction - Патч зображення (контейнер пікселів у більшому вигляді).
26. F – функція.

ВСТУП

Актуальність. Проблема вдосконалення діагностики та вибору найкращої тактики лікування пухлин молочної залози залишається однією з найбільш актуальних в сучасній хірургічній практиці [10, 45].

Для діагностування ракових захворювань використовують цитологічні зображення. Сучасні засоби класифікації цитологічних зображень вимагають великих вибірок зображень. Для збільшення вибірки використовують генеративні засоби. В якості генераторів використовують генеративно-змагальні мережі.

Мета роботи полягає в синтезі цитологічних зображень на основі генеративно-змагальних мереж. Тому, щоб досягти поставленої мети потрібно виконати завдання:

- 1) проаналізувати цитологічні зображення раку молочної залози;
- 2) проаналізувати архітектури генеративно-змагальних мереж;
- 3) розробити алгоритми для генерування цитологічних зображень;
- 4) здійснити класифікацію зображень на основі згорткових нейронних мереж;
- 5) здійснити комп'ютерні експерименти для синтезу цитологічних зображень.

Завдання виконувалися згідно методичних вказівок [1, 2]

Наукова новизна одержаних результатів полягає у розробленні алгоритмів синтезу зображень передракових та ракових станів молочної залози.

Методи дослідження. Теоретичні дослідження ґрунтуються на застосуванні теорії нейронних мереж, теорії алгоритмів та об'єктно-орієнтованого проектування.

Практичне значення полягає у формуванні штучної бази даних цитологічних зображень .

Публікації та апробація ВКР.

1. О.М. Березький, П.Б. Лящинський, П.Б. Лящинський, А.Р. Сухович, Т.М. Долинюк. Синтез біомедичних зображень на основі генеративно-змагальних мереж // УЖІТ 2019 №1 (прийнято до друку) [3].
2. Синтез біомедичних зображень на основі генеративно-змагальних мереж: зб. тез наук.-практ. конф. / Інтелектуальні комп'ютерні системи та мережі, Тернопольського національного економічного університету. — К.: ФКІТ, 2019. — 55 с. [4]
3. Синтез цитологічних зображень на основі згорткових нейронних мереж: зб. тез II наук.-практ. конф. Молодих вчених і студентів / Інтелектуальні комп'ютерні системи та мережі, Тернопольського національного економічного університету. — К.: ФКІТ, 2019. — 41 с. [5].

У магістерській роботі міститься три розділи:

У першому розділі подано аналіз методів і алгоритмів синтезу зображень. Проведено аналіз цитологічних зображень, архітектур штучних нейронних мереж, а також програмних забосів синтезу зображень.

У другому розділі проаналізовано структури генеративно-змагальної мережі, глибоко-згорткових генеративно-змагальних мереж, а також застосування цих структур генеративно-змагальних мереж для синтезу зображень.

У третьому розділі розроблено програмну реалізацію модуля синтезу зображень. Також розроблено структуру програмного модуля; архітектуру згорткової нейронної мережі та здійснено порівняльний аналіз результатів класифікації зображень.

1 АНАЛІЗ АЛГОРИТМІВ СИНТЕЗУ ЦИТОЛОГІЧНИХ ЗОБРАЖЕНЬ НА ОСНОВІ НЕЙРОННИХ МЕРЕЖ

1.1 Аналіз цитологічних зображень

Зображення - це двійкове подання візуальної інформації, таке як креслення, малюнки, графіки, логотипи або окремі відеокадри. Цифрові зображення можна зберігати в електронному вигляді на будь-якому пристрої зберігання даних. Наступний приклад зображення - це модифіковане зображення процесора комп'ютера з тепловідводом. У цьому прикладі для фотографування була використана цифрова камера, а потім додано текст за допомогою програмного забезпечення для редагування фотографій для створення зображення.[8, 9]

Зображення можна визначити як двовимірну функцію $f(x, y)$, де x і y - координати в просторі (конкретно на площині) і значення f якої в будь-якій точці, що задається парою координат (x, y) , називається інтенсивністю або рівнем зображення в цій точці. Якщо величини x , y і f приймають кінцевих число дискретних значень, то говорять про цифрове зображення. Цифровою обробкою зображень називається обробка цифрових зображень за допомогою обчислювальних машин, або комп'ютерів. Зауважимо, що цифрове зображення складається з кінцевого числа елементів, кожен з яких розташований в конкретному місці і приймає певне значення. Ці елементи називаються елементами зображення або пікселями. Найчастіше для елементів цифрового зображення використовується термін «піксель». [6]

Цитологія – це наука, що вивчає функції, будову клітин одноклітинних та багатоклітинних організмів. Є два типи цифрових зображень: цитологічні та гістологічні. Розгляньмо детальніше цитологічні. [7, 8]

Цифрові зображення з високою роздільною здатністю в трьох вимірах (3D). Деякі з цих мікроскопічних технологій візуалізації можуть навіть надавати зображення на субклітинному рівні. Деякі методи були поєднані з оптикою волокон, що дозволяє інтегрувати їх з такими пристроями, як ендоскопи, які

дозволяють отримувати «оптичні біопсії» всередині тіла. Ці способи візуалізації мають захоплюючий потенціал у діагностичній патології та біомедичних дослідженнях. 1-3 В останнє десятиліття кілька цих нових технологій були успішно застосовані до зразків цитологічних зображень. Тому очікується поява нових застосувань у галузі цитопатології, таких як скринінг *in vivo*. Отже, важливо, щоб цитологи знали цю тенденцію візуалізації, розуміли ці передові методики візуалізації, а також потенційний вплив, який вони можуть мати на область цитопатології. У цій статті розглядається застосування декількох сучасних методів візуалізації, нещодавно застосованих до цитології, таких як оптична когерентна томографія (ОСТ), 3D-томографічна томографія, кількісна фазова мікроскопія (QPM), течія візуалізації та масова цитометрія.[7]

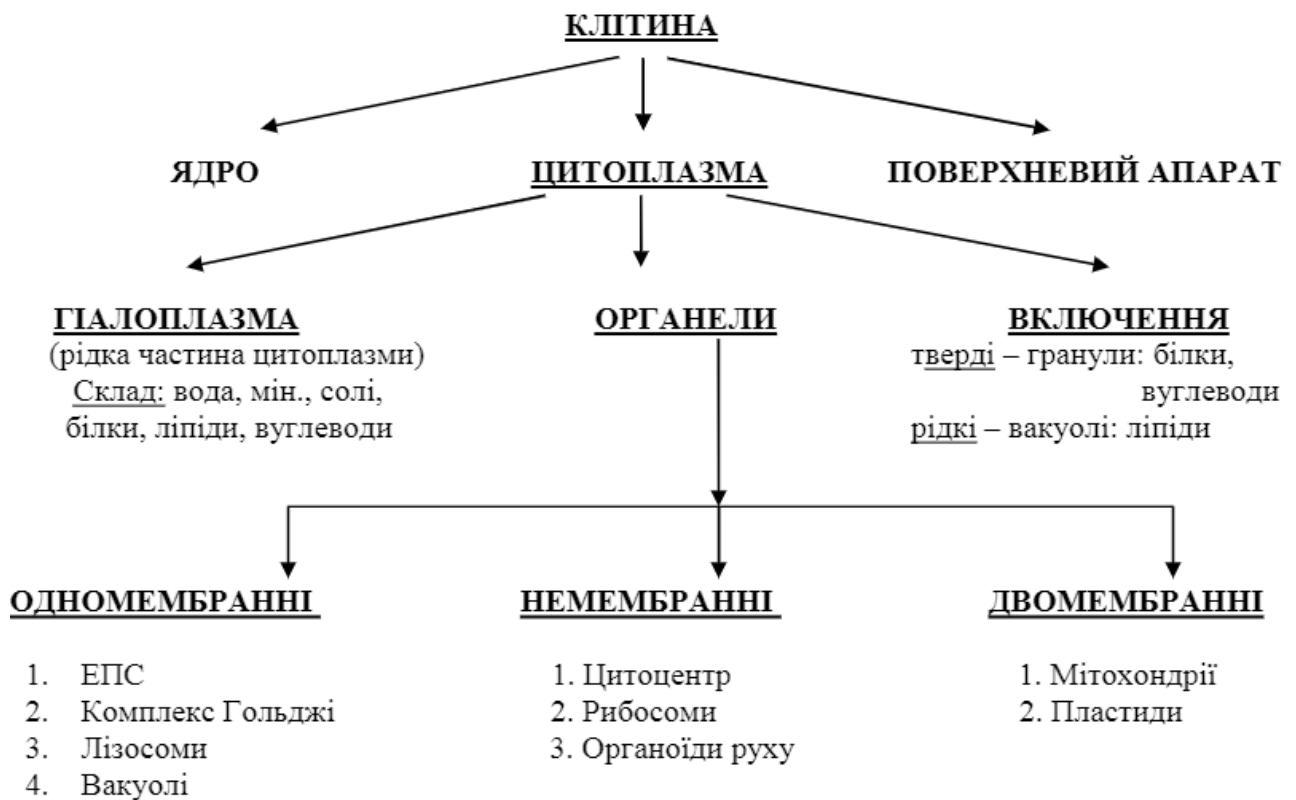


Рисунок 1.1 – Загальна будова клітини

Ядро - необхідне для функціонування клітини, оскільки саме воно містить генетичну інформацію у формі ДНК. Тут відбувається не тільки збереження, а й реалізація спадкової інформації: процеси транскрипції, що є початковим етапом біосинтезу білків, які регулюють переважну більшість процесів у клітині, та

реплікації, що забезпечують точне відтворення ДНК клітини для дочірних клітин. Ядро оточене двошаровою ядерною оболонкою, в якій є отвори — ядерні пори. [7]

Цитоплазма – складається із водянистої основної речовини — гіалоплазми, у якій розташовані органели, нитки цитоскелету та клітинні включення.

Гіалоплазма - основна речовина цитоплазми приблизно на 90 % складається з води, в якій розчинені всі основні біомолекули: солі, цукри, амінокислоти, нуклеотиди, вітаміни і гази утворюють істинний розчин, тоді як великі молекули, зокрема білки, перебувають у колоїдному розчині. Органели - це частина еукаріотичної клітини, яка виконує специфічну функцію. Органели були виявлені за допомогою різноманітних форм мікроскопії або завдяки клітинному фракціонуванню.

Клітинні включення — це гранули, краплі або кристали певних речовин, що накопичуються у цитоплазмі клітини. На відміну від органел є непостійними і необов'язковими структурами. Найчастіше у формі включень організми запасують поживні речовини, наприклад, краплі жиру в адипоцитах, гранули глікогену в клітинах печінки та крохмалю в багатьох рослинних клітинах. Також включеннями можуть бути пігменти або продукти обміну.

Одномембранна органела еукаріотичних клітин у вигляді замкненої системи каналців і плоских мембранних мішечків-цистерн. Мікротрубочки — це порожнисті циліндри, що складаються зі спіральньо розташованих димерів білка тубуліну. Мікротрубочки можуть збиратися або розбиратися в залежності від потреб клітини шляхом полімеризації або деполімеризації тубуліну. Мікротрубочки беруть участь у підтриманні форми клітини, зокрема запобігають її стисканню, у внутрішньоклітинному транспорті, а також забезпечують розходження хроматид.[9, 11]

Також є інші складові, з яких складається клітина, такі як: рибосома, лізосома, пероксисома, мітохондрії, хлоропласти. Для повноцінного аналізу та дослідницької роботи використовуються зображення. Зокрема, цитологічні

зображення – це RGB мікроскопічні зображення, в яких клітини знаходяться поза межами тканини.




Рисунок 1.2 – Цитологічне зображення

Добре відомо, що глибоке навчання дає кращі результати, ніж звичайні методи класифікації зображень [8, 9, 11]. Проблема візуального розпізнавання великого масштабу з використанням, а глибока звивиста нейронна мережа для класифікації зображень з високою роздільною здатністю. Крім того, є багато дослідницьких груп досліджували застосування на медичних знімках [11–13].

Для патологічних зображень за допомогою методів глибокого навчання запропоновані різні методи САПР. Наприклад, було розроблено систему, яка використовує згорткові нейронні мережі для підрахунку мітозу при первинному оцінці раку молочної залози [14]. Ван та ін. комбіновані функції ручної роботи і глибокі звивисті нейронні мережі для виявлення мітозу. [15]. Ертосун та Рубін запропонували автоматизовану систему для класифікації гліоми з використанням глибокого навчання [16]. Розвинені глибока звивиста нейронна мережа, яка сегментує і класифікує епітеліальні та стромальні області в гістопатологічних образи [17]. Досліджував вплив глибокого, навчившись гістопатологічному

дослідженню та перевірив його ефективність була чудовою для виявлення раку простати виявлення метастазів раку молочної залози [18].

Наскільки нам відомо, не застосовувались цитологічні зображення для класифікації раку легенів. Найпоширенішими інструментами діагностики є мамографія та біопсія аспірації тонкої голкою. Мамографія, яка є неінвазивним методом, найчастіше застосовується для скринінгу, а не для точної діагностики. Біопсія аспірації тонкої голки – це інвазивний метод вилучення невеликого зразка сумнівної тканини молочної залози, що дозволяє патологоанатомові описати тип раку детально. За допомогою цього методу патологоанатоми можуть дуже адекватно описати не тільки тип захворювання рак, а також його генеалогію та злоякісність. Вони можуть також передбачають перебіг розвитку раку, приписуючи йому прогностичний фактор. Стадія раку залежить на фактор злоякісності, який призначається під час FNA експертиза. Визначення злоякісності має важливе значення при прогнозуванні прогресування раку.[18]

Усі ці підходи є зосереджено на класифікації зображень як доброякісних чи злоякісних. Ці особливості використовуються для призначення ступеня діагностованої тканини.

Однією з найпопулярніших і широко застосовуваних схем класифікації цитологічної тканини є схема градування Блума-Річардсона (Bloom and Richardson, 1957). Таку ж шкалу легко можна використовувати для оцінки злоякісності цитологічних мазків. Відповідно до цього у системі є три фактори, які враховуються під час сортування ракової тканини. Кожен з трьох факторів оцінюється за трибальною шкалою відповідно до наступного опису:

1. Ступінь структурної диференціації: каналцева утворення, яке відображає схильність клітин до утворення каналців. Оскільки в цитологічних мазках каналців немає. Збережене, наступне оцінювання цього фактора ґрунтується на класифікації клітинних угруповань в межах.

- Один момент: комірки на зображенні групуються регулярно.

- Два моменти: можуть бути згруповані та окремі клітини знаходиться у межах зображення.

- Три моменти: клітини поширені нерегулярно.

2. Плеоморфізм (P): Цей фактор враховує різницю у розмірах, формі та фарбуванні ядра. Цей бал досить простий, оскільки зі зростанням нерегулярності ядер прогноз стає гіршим.

- Один момент: ядра однакового розміру, форми та фарбування

- Два моменти: виявлені помірні зміни.

- Три моменти: дуже суттєві зміни.

3. Частота гіперхроматичних та мітотичних фігур: Мітоз - це процес у життєвому циклі клітин в якій материнська клітина ділиться на дві однакові клітини. В центральній частині можна помітити тонку межу між двома ядра. Також можна побачити більш темний відтінок фарбування.

Основна мета цього фактора - оцінка кількості мітотичних фігур у розглянутому полі. Кілька поля зору на одному слайді враховуються, оскільки цей крок робиться у великому збільшенні. Чим більше виявлених випадків мітозу, тим гірший прогноз:

- Один момент: знаходяться випадкові цифри на поле.

- Два моменти: мазки двома або трьома фігурами більшість полів.

- Три бали: більше трьох цифр на поле знайдені.




Рисунок 1.3 - Групування клітин: (а) розповсюджені клітини, (б) згруповані клітини.




Рисунок 1.4 - Варіанти розміру, форми та фарбування, як показано на рис стрілки: (a) дуктальна карцинома, (b) G3 дуктальна карцинома.

Оцінка злоякісності пухлини вказує на ймовірність того, що справа може перенести метастази під час або після лікування. Він також має вплив на тип лікування пацієнта. Тому призначення діагнозу випадку є дуже складним завданням і залежить від досвіду патологоанатома. З іншого боку, належне перевтома і втома, бачачи більше подібних випадків призводять до неправильної класифікації злоякісності. У нашому методі вхідний фрагмент спочатку попередньо обробляється та сегментується, згідно алгоритму. На основі результатів сегментації обчислюються ознаки, що враховуються та використовуються для навчання класифікатор. Тут класифікуються зображення FNA в один із три класи, що представляють ступінь злоякісності. [7]

Набір даних зображень сімдесят шість (76) випадків ракових клітин були зібрані ексfolіативною або інтервенційною цитологією аспірації тонкої голки з бронхоскопією або цитологією АС.

Позитивність нейроендокринних маркерів, включаючи хромогранін А, синаптофізин, свідчить про малі клітинний рак. Цитологічні зразки готували за допомогою системи цитології на основі рідини (LBC) за допомогою тесту Рар-тесту на основі рідини на основі і фарбували за допомогою методу Папаніколау.

Початковий розмір матриці кожного JPEG зображення було 2040×1536 пікселів. Згодом 768×768 пікселів квадратних зображень було сформовано шляхом обрізання та було додатково змінено до 256×256 пікселів. Згодом дублюватиметься квадратні зображення 768×768 пікселів були вирізані з

оригінального зображення, щоб не викликати перекриття звідти. Нарешті, вони були змінені до 256×256 пікселів.

Цитологічні зображення клітин збираються для формування набору даних, що містить близько 30 нормальних і шкідливих випадків. Приклад зображення показаний на рисунку 1.5.




Рисунок 1.5 - Цитологічне зображення

Особливість аналізу зображень злоякісних клітин полягають у тому, що ядро більше розширене і займає більшу частину цитоплазми клітини, як видно на рисунку 1.6. В області сегментованих ядер зображення злоякісної клітини містить ділянки темного та щільна текстура, в той час як нормальна містить легкі і розріджені структури. Вони відповідають різним значенням текстури особливості. Нормальні клітини відзначаються меншою грубістю, кореляцією, однорідністю та енергією, тоді як злоякісні клітини виявляють нижчий контраст. Визначається, що спрямованість не відрізняється між класами зображень.




Рисунок 1.6 - Злоякісні клітини (вгорі) і нормальні клітини (знизу)

Отже, було представлено метод пошуку вмісту та діагностики на основі вмісту цитологічних зображень з використанням підходу з функціями. Були використані функції текстури, за допомогою яких сформувався метод подання зображення. Експериментами продемонстровано ефективність підходу з хорошою точністю класифікації.

1.2 Аналіз архітектур штучних нейронних мереж

Штучна мережа – це мережа, що базується на штучному нейроні. Властивістю даних мереж є велика кількість певних з'єднань, які поєднують нейронами. Нейрони у головному мозку людини, а також їх групування може забезпечувати обробку інформації самоорганізуючим, динамічним чи інтерактивним шляхами.

З'єднуючись у мережі, нейрони утворюють систему, що обробляють інформацію, яка має ефективну адаптацію певної моделі, що змінюється зі сторони навколишнього середовища. В процесі виконання функцій мережі вхідний вектор сигналу перетворюється у вихідний. [19]

ADALINE, що є адаптивним суматором - стандартний елемент систем обробки певних сигналів. У 1961 році під керівництвом Бонгарда була

розроблена програма «Кора». Завдання Кори — це пошук правила після того, як знайдені оператори, що дають досить чіткі характеристики об'єкту або його частин. [9]

Метод, що розвивався, зворотного поширення помилки та нейронні мережі повільно почали відновлювати у експериментах та дослідженнях. [10]

Взагалі, штучна нейронна мережа може бути розділена на три частини, називаються шари, які відомі як:

а) вхідний шар. Цей шар відповідає за отримання інформації, сигналів, функцій або вимірювання зі зовнішнього середовища. Ці входи зазвичай нормалізуються в межах граничних значень, отриманих під час активації функції. Ця нормалізація забезпечує числову точність та математичні операції, що виконуються мережею.

б) сховані, проміжні, невидимі шари, що складаються з нейронів, які відповідають за видалення схеми, пов'язані з аналізом процесу або системи. Ці шари необхідно виконувати більшу частину внутрішньої обробки.

в) вихідний шар. Даний шар складається з певних нейронів і, таким чином, відповідає за створення цих нейронних зв'язків і, представляючи остаточні вихідні мережі, що є результатом обробки, виконаних нейронами в попередніх шарах. [10] Одні з основних архітектур штучних нейронних мереж, враховуючи нейронне розташування, а також як взаємопов'язані та як шари складені, необхідно поділити наступним чином: (1) одношарова передавальна мережа, (2) багатошарові канали передачі, (3) періодичні мережі та (2) сітка мережі. Також є певні види архітектури мережі, такі як:

а) одношарова архітектура мережі: ця штучна нейронна мережа має лише один вхідний шар і один нейронний шар, який також є вихідним шаром. Інформація протікає в одному напрямку, таким чином, є односпрямованим, від вхідного шару до вихідного шару. З рисунку 1.1 видно, що в мережі, яка належить до даної архітектури, кількість мережевих виходів завжди збігається з його нейронною кількістю. Ці мережі зазвичай використовуються в класифікації зразків та проблеми лінійної фільтрації [11].

Серед основних типів мереж, що належать до просторової архітектури, є перцептрон та ADALINE, їх алгоритми навчання використовуються при підготовці процесів, що засновані відповідно до правила Хебба, а також правила дельти.[22]

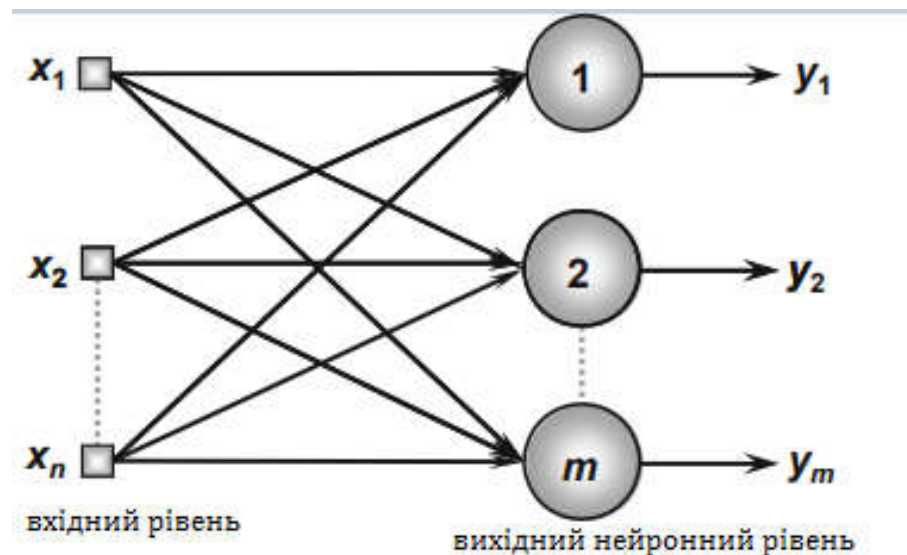


Рисунок 1.7 – Приклад одношарової мережі

б) багатшаровий потік архітектури. На відміну від мереж, що належать до попередньої архітектури, мережі з рівнями, складаються з одного або декількох прихованих нейронних шарів. Ці мережі працюють з метою вирішення проблем, таких як для функціонування наближення, оптимізація, ідентифікації системи, робототехніка, класифікації моделей, процесу контроль тощо [11].

На рисунку 1.8 показана мережа з прямим зв'язком, що складається з кількох шарів, а саме з одного вхідного шару з n сигналами вибірки, двох прихованих нейронних шарів, а також складаються з n_1 і n_2 відповідно, нейронів, один вихідний нейронний шар, що складається з m нейронів, представляють відповідні вихідні значення проблеми, що аналізується.

Серед головних мереж, що використовують, є багаторівневі попередні архітектури, багатшаровий перцептрон (MLP) та радіальна функція основи (RBF), що використовуються в навчальних процесах, відповідно ґрунтуються на підсумковому дельта-правилі і конкурентному дельта-правилі [7].

З рисунку 1.8 видно, що кількість нейронів складається з одного прихованого шару, що зазвичай відрізняється від кількості сигналів, що складають вхідний шар мережі. Фактично, кількість прихованих шарів і їх відповідних кількості нейронів залежить від характеру та складності проблеми, що наведені мережею, а також кількості та якості наявних даних про проблему. Для простих шарів, каналів передачі кількість вихідних сигналів завжди буде збігатися з кількістю нейронів від відповідного шару [10].

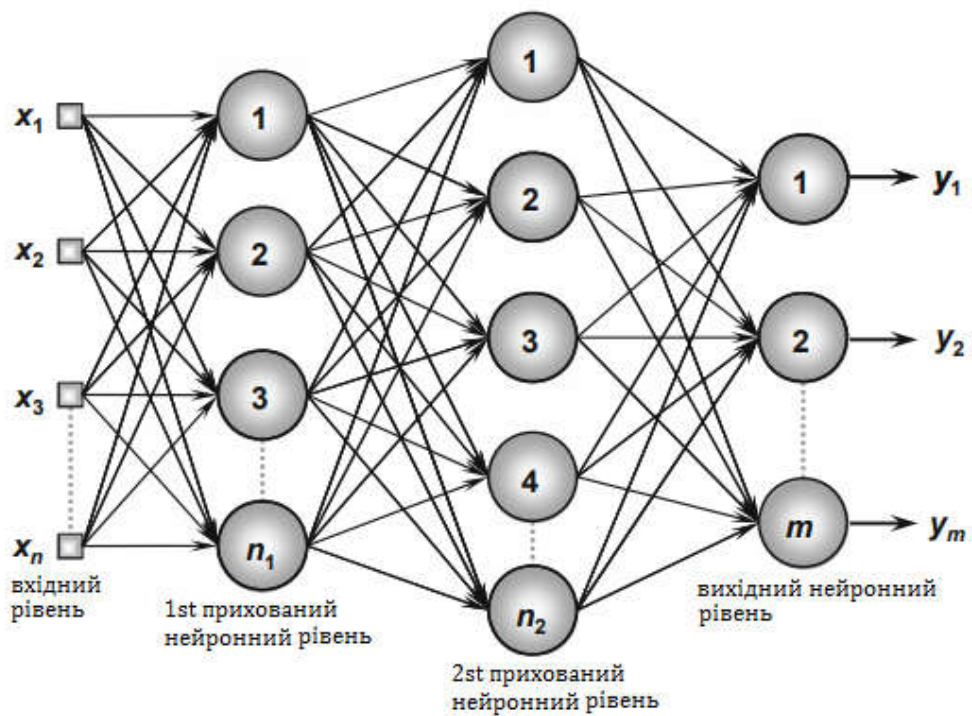


Рисунок 1.8 - Приклад перетворюючої мережі з декількома шарами

У 1998 році Янн Лекун розробив справді досить чітке розпізнавання для рукописних цифр під назвою LeNet. Вона використовувалася для зворотного поширення в прямої мережі та з багатьма прихованими шарами, багатьма картами, що повторюють вузли у кожному шарі, об'єднанням результатів найближчих повторюваних вузлів яких є, широкою мережею, що може проаналізувати кілька символів відразу, навіть якщо вони перекриваються, і розумним способом навчання повної системи, а не просто розпізнавання.[11, 12]

Протягом багатьох поколінь розвитку основна увага приділялася прийняттю рішень на різних рівнях деталізації, в тому числі, починаючи від

низькорівневої обробки пікселів над інженерною діяльністю в поєднанні з контрольованим вивченням класифікаторів до недавньої хвилі функціонального навчання з використанням згорткових нейронних мереж (CNN). Основний фокус машинного навчання на основі медичного аналізу перебуває під контролем вивчення меж та прийняття рішень.[13]

Пізніше він формалізований під назвою приєднувальних нейронних мереж (CNNs) [11, 12].

Унікальна здатність (ГЗМ), запроваджений наслідувати розподіл даних відкрив можливість подолати розрив між навчанням та синтезом. Швидке розширення ГЗМ сприяє синтезу образів реалістичного вигляду на безпрецедентному рівні. Причини за цією перевагою пов'язані дві основні властивості. По-перше, ГЗМ як метод навчання без нагляду, спрямований на отримання інформації над даними, непрямим способом нагляду. По-друге, ГЗМ показали суттєве значення підвищення продуктивності у витягуванні візуальних особливостей шляхом виявлення максимуму розмірне латентне розподіл даних. Цей огляд підсумовує архітектури на основі ГЗМ, запропоновані для програм медичного оброблення зображень, включаючи синтез, сегментацію, реконструкцію, виявлення, зняття шуму, реєстрація та класифікація. Надаються таблиці для отримання швидкого доступу до ключової інформації, наприклад, про ефективність методів, показників, набори даних, модальність зображень та загальний формат запропонованої архітектури. Більше того, обговорюються переваги та недоліки методів. [14]

Під наглядом глибоке навчання в даний час є найсучаснішим у багатьох завданнях комп'ютерного зору та медичного аналізу зображень. Однак головне обмеження: фактор цієї парадигми не лише в контексті медичних застосувань – її залежність від великої кількості анотованих даних про навчання. У галузі медицини це особливо важливо, як придбання та маркування медичних зображень вимагає експертів, є стомлюючим, трудомістким і затратним, що призводить до важкої ситуації відсутність мічених даних про навчання.[6]

Генеративне моделювання потенційно може виступати полегшенням для вирішення даної проблеми машинного навчання. Прикладне дослідження ГЗМ для медичну томографію можна широко класифікувати на наступні категорії на основі вхід і вихід: 1) прихований простір для зображення, і 2) зображення для зображення. [15]

У межах прихованого простору до зображень категорія ГЗМ показала свої можливості створювати зображення. Під припущенням, що ГЗМ можуть створювати значущі зразки, що покращують існуючі набори даних та несуть їх корисна інформація, різноманітні дослідження вже проведені для медичних синтезу та реконструкції зображення.

Концепція тренінгу, що стоїть за ГЗМ, теоретично виключає необхідність моделювання явних піксельних об'єктивних функцій шляхом засвоєння великої метрики подібності, щоб розповісти реальне і підроблені дані. Це дозволяє оптимізувати концепції для зображень поза межею піксельного рівня, що призводить до більш реальних результатів. Така приваблива властивість була недавно експлуатується для покращення сегментації та реєстрації медичних зображень, поліпшення зображень, таких як Denoising та вирішення загальної проблеми зміни домену на медичних зображеннях з використанням методів перекладу зображення на зображення на основі ГЗМ. При нестачі зазначається і одночасно велика кількість незазначених даних, парадигма напівконтрольного навчання пропонує різні рамки для моделей машинного навчання шляхом забезпечення подібних або неоднакової поведінки моделі для подібних або несхожих точок даних, де схожість потребує відповідного визначення. Знову ж таки, поняття подібності є вирішальним параметром і часто дуже залежать від даних. За таких умов ГЗМ також виявився корисним для підготовки класифікаторів чи зі зміною доменних даних у медичних даних.[16]

У контексті цієї роботи є три змагальні концепції, які слід правильно розуміти їх різні значення. Нападний напад означає внести непомітні зміни до зображення таким чином, що класифікатор неправильно класифікує його, тоді як він міг успішно класифікувати немодифікований образ. Зазвичай синтезоване

зображення, яке називається змагальним зображенням або змагальними прикладами, не є схожим з оригінальним зображенням візуально. Ефективність цієї ідеї стає очевидною, коли працюють в ГЗМ. Іноді ГЗМ неправильно прописують як змагальне навчання, але необхідно розмежувати це. Насправді ГЗМ складається з двох типів мереж та використовують змагальне навчання.

Основна перевага ГЗМ – це знайти схожість, яка відображає високу модель на розподіл реальних даних, зосередивши увагу на базовій щільності ймовірності даних. Це призводить до дуже різких розподілів навколо даних, які можуть бути використані для переродження цих даних.[17]

Хоча ГЗМ демонструє такі властиві переваги перед дискримінаційно навченими CNN, також є деякі проблеми: 1) колапс режиму: коли G руйнується для відображення всіх вхідних проміжків простору на ті самі дані та 2) нестабільність: що призводить до генерації різних виходів для одного входу. Основна причина - явище зникає градієнтами через процедуру оптимізації. Хоча пакетна нормалізація виступає як рішення нестабільності ГЗМ, недостатньо для підвищення продуктивності ГЗМ до оптимальної стабільності.

Спочатку ГЗМ були запропоновані як повністю без нагляду генератори, з метою відображення випадкового шуму до штучного, реалістично дивлячись зображення після розподілу навчальних даних. З умовним ГЗМ, також була успішно перетворена на контрольовану генеративну систему, обумовлюючи як генератора, так і дискримінатора попередні знання, а не лише шум.

Генеративні властивості обох каркасів були використані в різні способи синтезу певних типів медичних зображень або від шуму даних зображення. Далі, широкий огляд творів із безумовного та умовного буде надано синтез зображень. У конкретному випадку для умовних підходів, класифікуються внески на основі модальності зображення. [18]

Синтез реалістично виглядає у медичних образах відкривають багато нових можливостей для вирішення відомих глибин проблеми у навчанні, такі як дисбаланс класу, збільшення даних [14] або їх відсутність мічених даних. Крім того, це полегшує моделювання даних [15] та допомагає отримувати більш

глибоке розуміння природи розподілу даних та їх прихованої структури. Початкові результати показали, що ГЗМ можна використовувати для синтезу реально шукаючи ділянки ураження передміхурової залози [16] або зображення сітківки [17]. Обидва підходи покладаються на архітектуру глибоко-згорткової мережі (DCGAN) для синтезування патчів у роздільній здатності 16×16 пікселів та 64×64 пікселів відповідно.

Для кожного класу тренується генеративна модель. Оскільки навчальний набір даних спочатку досить малий, вони використовуються суттєво доповнені дані для навчання ГЗМ. Класифікацію демонструють додаткові синтетичні зразки збільшення даних, що може значно покращити конволюційну нейронну мережу класифікатор.[18]

Можливо, через велику розбіжність у навчальних даних, мала кількість зразків виявилася недостатньою для підготовки надійного DCGAN, проте ієрархічний LAPGAN та його варіанти показали багатообіцяючі результати синтезу. Частково штучні зразки використовуються для збільшення даних при навчанні класифікатора ураження шкіри. У [20] ті ж автори застосували нещодавно запропоновану концепцію прогресивного вирощування ГЗМ для синтезу зображень та показали приголомшливі, дуже реалістичні штучні зображення.[20]

Отже, для їх вирішення було введено багато підкласів ГЗМ недоліки. Тут представлені деякі найпоширеніші. Крім того, багато глибоких мереж на базі ГЗМ запропоновано спеціально для медичного зображення та обробки проектів, в яких використовуються різні функції архітектур та підвищення надійності, точності глибоких мереж. Перенести у інший підрозділ

Згорткові нейронні мережі відрізняються від більшості інших мереж. В основному використовуються для обробки зображень, але можуть використовуватися для інших входів. Частим випадком використання CNN є те, де передаються мережеві зображення, і дана мережа класифікує дані. Згорткова нейронна мережа, як правило, починаються з вхідного аналізатора, який не призначений для аналізу усіх навчальних даних одночасно. Для того, щоб ввести

зображення розміром 100 x 100 пікселів, потрібно шар не з 10 000 вузлів, швидше за все, створюєте шаблон сканування, що відповідає 10 x 10, на який підредагуєте на 10 x 10 пікселів зображення. Після того, оголосите вхід, то можна подавати наступні 10 x 10 пікселів, а також перенести аналізатор в один піксель вправо [17].




Рисунок 1.9 – Архітектура згорткової нейронної мережі

Вхідні дані подаються через згорткові шари замість звичайних шарів, де не всі вузли з'єднуються з усіма вузлами. Кожен вузол відноситься лише до сусідніх клітин. Такі згорткові шари, як правило, зменшуються, коли вони стають більш глибокими, в основному легко подільними факторами входу. Окрім цих згорткових шарів, у них також присутні об'єднання шарів. Поєднання є способом відфільтрувати деталі: максимальне об'єднання, де приймаємо 2 x 2 пікселі і передаємо пікселю найбільшу кількість червоного кольору [18].

Також у згортковій нейронній мережі є певні класи, що класифікуються такими термінами:

- Одношарові мережі прямого поширення. У багатошаровій нейронній мережі нейрони розташовуються за певними частинами. Найпростіший випадок такої мережі існує у вхідному шарі (input layer) вузлів джерела, інформація, яка передається на вихідний шар (output layer) нейронів, обчислювальних вузлів. Тому дана мережа має назву мережа прямого поширення (feedforward) [21].




Рисунок 1.10 - Мережа прямого поширення з одним шаром нейронів

На рисунку 1.10 показана структура мережі для випадку чотирьох вузлів в кожному з шарів (вхідному і вихідному). Дана нейронна мережа називається одношаровою (single-layer network), водночас, під шаром мається на увазі шар обчислювальних нейронів. Під час підрахунку числа шарів обчислюємо лише вузли джерела, тому що вони не виконують ніяких обчислень.

Наступний клас нейронних мереж прямого поширення характеризується наявністю одного або декількох прихованих шарів, вузли яких є прихованими нейронами, елементами. Функція цих елементів полягає в зв'язку між зовнішнім вхідним сигналом та виходом нейронної мережі. Додаючи один чи кілька прихованих шарів, можна виділити статистику певного порядку. Така мережа дозволяє визначити глобальні властивості даних за допомогою з'єднань за наявності синаптичних зв'язків і підвищення рівня взаємодії нейронів [14]. Здатність прихованих нейронів виділяти статистичні залежності високого порядку є особливо важлива, адже розмір вхідного шару досить великий. Вузли вхідного шару мережі формують елементи вхідного вектору, які утворюють вхідний сигнал, що надходить на нейрони першого прихованого шару.[23]

Вихідні сигнали прихованого шару використовуються в якості вхідних для третього шару. Зазвичай нейрони кожного з шарів мережі використовують в якості вхідних сигналів вихідні сигнали нейронів тільки попереднього шару. Набір вихідних сигналів нейронів вихідного (останнього) шару мережі визначає загальний відгук мережі на вхідний образ, що сформувався вузлами джерела вхідного шару. [24]




Рисунок 1.11 - Повнозв'язна мережа прямого поширення з одним прихованим і одним вихідним шаром

Мережа, яку продемонстровано на рисунку 1.11, є мережею, яка має 10 вхідних, 4 прихованих і 2 вихідних нейрона. У загальному випадку мережа прямого поширення з входами та нейронами першого прихованого шару, нейронами другого прихованого шару, а також нейронами вихідного шару називається мережею. Нейронна мережа, що показана на рисунку 1.11, вважається повно (fully connected) в тому сенсі, що всі вузли кожного конкретного шару з'єднані з усіма вузлами суміжних шарів. Якщо деякі з синаптичних зв'язків відсутні, така мережа називається часткової (partially connected).[18, 25]

Рекурентна нейронна мережа дещо відрізняється від мережі прямого поширення наявністю одного зворотного зв'язку. Наприклад, рекурентна мережа

складається з єдиного шару нейронів, кожен з яких направляє свій вихідний сигнал на входи інших нейронів шару.[7]




Рисунок 1.12 - Рекурентна мережа без прихованих нейронів і зворотних зв'язків нейронів з самими собою

Архітектура такої нейронної мережі, що продемонстрована на рисунку 1.12, 1.13 відсутні зворотні зв'язки нейронів з самими собою. Рекурентна мережа, що показана на рисунку 1.12 не має прихованих нейронів. На рисунку 1.13 подано інший клас рекурентних мереж з прихованими нейронами, тут зворотні зв'язки виходять як з прихованих, так і з вихідних нейронів. [26]

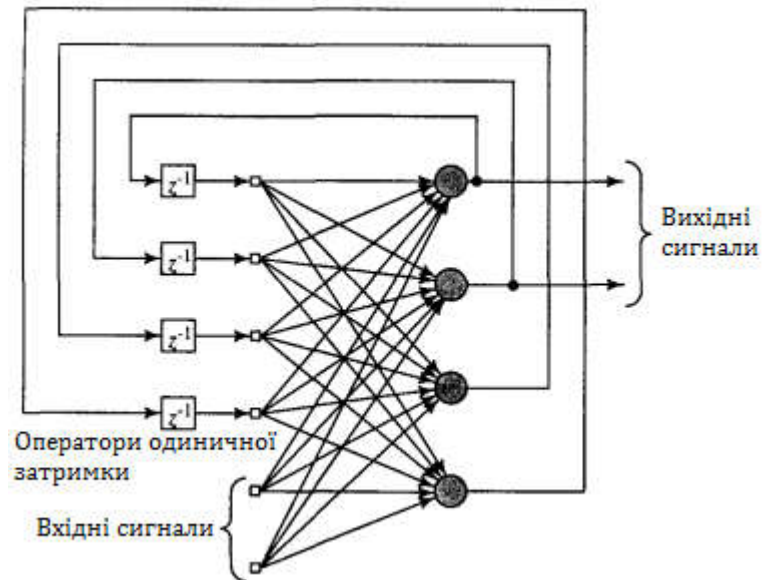


Рисунок 1.14 – Рекурентна мережа із прихованими нейронами

Наявність зворотного зв'язку в мережах, показаних на рисунках 1.14, що безпосередньо впливає на здатність мереж до навчання і на продуктивність. Окрім цього, зворотний зв'язок використовується для елементів одиничної затримки (вони позначені як z^{-1}), що призводить до нелінійної динамічної поведінки, якщо, звичайно, в мережі містяться нелінійні нейрони.

Архітектура нейронних мереж має завдання, а саме прогнозування і передбачення. Важливе значення мають ці задачі, серед яких можна виділити завдання з певними ознаками. Ці задачі поділено на класи:

- за характером головних ознак об'єктів (прогнозування явищ, що реалізуються за допомогою представлення у вигляді детермінованих рядів. Ці задачі можна вирішити через методи математичного аналізу; прогнозування явищ, які реалізуються за допомогою індетермінованих часових рядів. Процес виконання цих завдань здійснюється шляхом певних методів теорії ймовірностей, а також математичної статистики.) [6, 7].

- за числом особливостей об'єкту досліджень (одновимірне завдання - явище, що представлене однією ознакою, яка змінюється в часі; багатовимірне завдання – об'єкт, що вирізняється кількома особливостями.) [27, 28]

- розрізняють види прогнозів (згладжування, коротко-термінований, середньо-термінований, довго-термінований). Очевидно, що типи прогнозів дуже впливає на методіку і засоби реалізації.[28, 29]

Моделі навчаються захоплювати статистичний розподіл навчальних даних, що дозволяють синтезувати зразки з навченого розподілу. На додаток до синтезу нових зразків даних, які можуть бути використані для задач, таких як семантичне редагування зображень [15, 30], збільшення даних [16] і передача стилів [17], ми також зацікавлені у використанні уявлень, що такі моделі вивчають такі завдання, як класифікація [18, 31, 32] і пошук зображень [19].

Повністю пов'язані і згорткові шари глибоких мереж; це узагальнення перцептронів або просторових банків фільтрів з нелінійною постобробкою. У всіх випадках ваги мережі вивчаються зворотне поширення [20, 33, 34].

Отже, архітектури нейронних мереж спрямовані на навчання цих мереж зручним для аналізатора методом, а також, велика кількість типів архітектури дозволяє вибрати найбільш зручну і ефективну. Для архітектури є властивим такі задачі як прогнозування та передбачення, що дає змогу краще опрацьовувати вибірки і результати, прогнозувати їх, передбачати як вони впливатимуть, до прикладу, на організм людини, або ж, до чого саме це призведе, таким чином, полегшуючи аналіз певних вибірок нейронних мереж.

1.3 Аналіз програмних засобів синтезу зображень

Для обробки зображень, зокрема синтезу цитологічних та гістологічних зображень використовують різноманітні програми, загалом функціонуються по-різному, але мають певні нюанси.

Отож, програмне забезпечення AdobePhotoshop:

- Панель програми містить у верхній частині перемикач робочого середовища, меню та інші елементи керування програми.

- Панель інструментів містить компоненти для створення та графіки, редагування зображень, елементів сторінок. [22, 36]
- Панель параметрів відображає параметри для інструмента.
- У вікні документа відображається назва файлу, з яким виконується робота. Вікна документа можна групувати та в окремих випадках, накладати одне на інше, закріплювати.
- За допомогою панелей можна керувати проектом і змінювати його. Панелі можна групувати, закріплювати.
- Елементи середовища групуються в одне інтегроване вікно, яке дозволяє працювати з програмою як з елементом. Під час переміщення розміру рамки, програмні елементи, залежать, що попереджує накладання. При перемиканні програм або закриття програми панелі не зникають.
- Функції, підвищують зручність використання.
- Робоче середовище Photoshop просте у використанні й містить кілька функцій, для зручного користування:
 - Різні рівні яскравості: виберіть «Редагувати» > «Параметри» (Windows) або «Photoshop» > «Параметри» (Mac OS) і в розділі «Інтерфейс».
 - Дані на зображенні: інформація про використання інструментів.
 - Максимальне збільшення екранного простору: натисніть кнопку панелі інструментів, щоб вивести «Стандартний» режим на «Повноекранний».
 - Налаштування кольору користувацького інтерфейсу. Можна використовувати в інтерфейсі Для цього виконайте такі дії:
 - Виберіть «Редагувати > Параметри > Інтерфейс».
 - Виберіть потрібну колірну тему.

Програмне забезпечення CorelDraw: програма є векторною програмою. Створюється коло по принципах креслення, програма знає, що це коло з x- і y-координатами, радіусом, центром, зовнішньою границею і кольором внутрішнього тла. Можна змінювати форму, розмір і колір кола не порушуючи його суті.[31, 37]




Рисунок 1.15 – Варіанти кольорових тем

Програма Corel Photo-Paint, входить у пакет Corel Draw відноситься до цієї категорії. Коли створюється коло в Photo-Paint чи в іншій подібній програмі, застосовуючи електронну фарбу індивідуально для кожного пікселя вашої електронної полотнини. Створюється — нічого більш, як набір крапок об'єднаних у лінію, кожна крапка має свій колір.



Рисунок 1.16 – Програмне забезпечення CoralDraw

- Висока здатність, що дозволяє, при печатці. Коли друкується з DRAW, те намальовані об'єкти будуть друкуватися з максимально високим ступенем дозволу.
- Більш швидка печатка і створення малюнка на екрані. DRAW не цікавлять окремі піксели. Він повідомляє набагато менше інформації принтеру й екрану, чим програми, - виходить растрове зображення.
- Високий рівень редагованості. Векторне зображення складається з кривих, із крапок їхнього перетинання і зіткнення.
- Недостача реальності в накреслених об'єктах. При усіх своїх достоїнствах, векторно створений об'єкт не виглядає так життєво, як растровий.
- Протилежність. Коли відкривається Corel Photo-Paint, Ставлячи окремі крапки на електронній полотнині — справді малюєте.

- Растрові програми мають наступні характеристики. [32]
- Обмежена здатність, що дозволяє. Крапки на растровому зображенні мають фіксований розмір і вилучені одна від іншої. Задавши в програмі установки образу печатка щільністю 300 крапок на дюйм (dpi) для лазерного принтера, ви не зможете потім змінити її на 1200 dpi. Крапки зберігаються такими, як є, і ніяке редагування не може їх чи зменшити наблизити.
 - Великий розмір файлів. Оскільки растри — це крапки, то вони займають великий обсяг твердого диска, оперативної і відео пам'яті. Чим вище дозволяє здатність відеосистеми, тим більше крапок, і тем більше задіяно системних ресурсів.
 - Редагування пікселів. Відсутні критерії математичного контролю, що описують растрове зображення, але можливо здійснювати контроль самих крапок. Можна збільшити ділянку брови на зображенні обличчя й обрізати пари волосся, що на ваш погляд занадто довгі.
 - Високий ступінь реальності. Контролюючи кожен крапку, що створює зображення, можете імітувати життя на більш високому рівні, чим векторні програми. Редактор образів і гарний сканер дозволять створювати реальну фотографію.

Серйозні фахівці не обмежують вибором конкретної графічної програми, у дійсності використовують обидві програми CorelDRAW (DRAW і Photo-Paint) одночасно. Сьогодні часто зустрічаються електронні зображення, що одночасно містять текстові блоки, ділянки, створені за допомогою векторної графіки, і елементи, контрольовані програмами.

Програмне забезпечення Microsoft Visio — редактор діаграм для Windows і редактор векторної графіки.

Стандартна і професійна версія використовують той же інтерфейс, але інша має додаткові шаблони для більш просунутих діаграм і вихідних форматів, а також унікальну функціональність для простішого приєднання користувача до даних різних джерельних форматів, які мають бути відображені діаграмою.

Visio 2007 побачив світ 30 листопада 2006 року. Microsoft Visio може стати помічником в рішенні трьох основних задач: у аналізі складних даних, в графічному представленні даних і в обміні цими даними між користувачами. Основний засіб представлення даних в Visio — це векторні фігури, на основі яких будується діаграма або план. Для зручності фігури згруповані по тематичних категоріях, в кожній з яких можна побачити схожі на вигляд або по темі елементи. Основний засіб представлення даних в Visio — це векторні фігури, на основі яких будується діаграма або план. Для зручності фігури згруповані по тематичних категоріях, в кожній з яких можна побачити схожі на вигляд або по темі елементи. Фігури відображаються на однойменній області завдань. Фігури є основним, але не єдиним засобом для представлення даних в Visio. Окрім них можна також використовувати текст і числові дані, графічні елементи і форматування кольором. [7, 6, 38]

Найзручніший спосіб почати роботу з Visio — створити документ на основі шаблону. При завантаженні шаблону на область завдань «Фігури» підвантажуються ті категорії графічних елементів, які можуть вам знадобитися в процесі створення діаграми. [11]

Для більшості користувачів Visio є лише допоміжною програмою, яка використовується разом з Excel, Access, Microsoft SQL Server і іншими рішеннями. Іншими словами, не зважаючи на те, що в Visio є можливість введення даних вручну, в більшості випадків це невиправдано. Набагато простіше пов'язати діаграму Visio даними, які вводяться і обробляються в спеціальних застосунках, призначених саме для цього. Основна функція Visio — в наочнішому представленні вже наявних даних. Використання зовнішніх джерел має свої переваги. По-перше, набагато простіше пов'язати вже наявні дані з елементами діаграми Visio, чим вводити їх вручну. По-друге, при використанні зовнішніх джерел оновлення може відбуватися автоматично. [11]

Отже, це програмне забезпечення цитологічних, гістологічних зображень із баз, що використовуються для обробки, синтезу. [38]

1.4 Постановка завдання на магістерське дослідження

Метою роботи є синтез цитологічних зображень на основі генеративно-змагальних мереж. Тому, щоб досягти поставленої мети необхідно виконати завдання:

- 1) проаналізувати цитологічні зображення раку молочної залози;
- 2) Проаналізувати архітектури генеративно-змагальних мереж;
- 3) Розробити архітектуру генеративно-змагальної мережі для генерування цитологічних зображень;
- 4) здійснити комп'ютерні експерименти для синтезу цитологічних зображень.

Виходячи із проведеного аналізу цитологічних зображень, алгоритмів синтезу зображень, використання нейронних мереж для синтезу зображень та програмних засобів синтезу, задачами магістерського дослідження є:

- 1) здійснити аналіз цитологічних зображень раку молочної залози, що дало можливість виділити характерні ознаки цих зображень;
- 2) проаналізувати архітектури штучних нейронних мереж для аналізу та синтезу зображень, що дало змогу обґрунтувати напрям дослідження;
- 3) проаналізувати структури генеративно-змагальних мереж (глибоко-згорткових генеративно-змагальних мереж) і розглянуто їх застосування для синтезу біомедичних зображень;
- 4) розробити структуру програмного модуля генерування цитологічних зображень, що дало змогу його програмно реалізувати;
- 5) розробити архітектуру згорткової нейронної мережі, яка лягла в основу побудови GAT мереж для синтезу зображень;
- 6) здійснити порівняльний аналіз класифікації цитологічних зображень, штучно згенерованих та реальних, отриманих дослідним шляхом.

2 СТРУКТУРИ СИНТЕЗУ ЗОБРАЖЕНЬ НА ОСНОВІ ГЕНЕРАТИВНО-ЗМАГАЛЬНИХ НЕЙРОННИХ МЕРЕЖ

У цьому розділі проаналізуємо основні архітектури ГЗМ. Це ГЗМ Вассерштейна, умовні ГЗМ, циклічні ГЗМ (CycleGAN), ГЗМ, що базуються на найменших квадратах, марківські ГЗМ.

2.1 Структури генеративно-змагальних мереж

ГЗМ [6] складається з генератора (G) та дискримінатора (D), а також навчальний набір реальних даних X. Мережа G – це штучна багатошарова мережа з параметрами θ_G , що має на меті знайти відображення, яке відноситься до прихованих випадкових величин $z \sim p_z(z)$ для штучних даних з розподілом $p_\theta(\hat{x}|z)$. Виявивши своє відображення, G генерує штучні дані, які, як передбачається, не можна відрізнити з реальних даних. З іншого боку, дискримінатор $D(x; \theta_D)$ має на меті відрізнити штучні зразки від реальних. Тим самим, дискримінатор $D(x)$ це:

- скалярний вихід мережі дискримінатора, який показує ймовірність того, що x є штучним, а не синтезованим з $p_\theta(\hat{x}|z)$ (рисунок 2.1). Дискримінатор D навчений так, щоб збільшити ймовірність правильного присвоєння мітки штучним і реальним даним, в той час як G навчений так, щоб дискримінатор шляхом мінімізації $\log(1 - D(G(z)))$ не міг відрізнити реальне та штучне зображення. Генератор і дискримінатор D і G грають у мінімакс-гру для двох гравців зі значенням функція $V(G, D)$:

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log(D(x))] + \mathbb{E}_{z \sim p_z(z)} [1 - \log(D(G(z)))] \quad (2.1)$$

Таким чином, генератор оновлюється лише через градієнти, розповсюджені назад від дискримінатора. Якщо генератор оптимізовано для

максимізації виразу ($D(G(z))$) замість мінімізації виразу ($1-D(G(z))$), то набагато сильніші градієнти можна отримати на більш ранніх ітераціях тренувань.

Таким чином, [20] процедура непрямой оптимізації не дозволяє компонентам вводу бути чітко запам'ятовуваним генератором. Основна перевага ГЗМ в тому, щоб знайти подібність, яка відображає модель розподілу реальних даних, що ґрунтується на базовій густині розподілу ймовірності даних. Це приводить до дуже різких розподілів даних, які можуть бути використані для перенавчання даних [39].

Хоча ГЗМ демонструє переваги перед дискримінаційно навченими ЗНМ, але має такі проблеми:

- 1) колапс режиму, коли G руйнується для відображення всіх вхідних проміжків простору на ті самі дані;
- 2) нестабільність, що приводить до генерації різних виходів для одного входу.

Основна причина - це зникнення градієнтів через процедуру оптимізації. Хоча пакетна нормалізація виступає як рішення нестабільності ГЗМ, але цього недостатньо для підвищення продуктивності ГЗМ до оптимальної стабільності.




Рисунок 2.1 – Структура ГЗМ

На рисунку 2.2 подано структуру умовної ГЗМ, яка розроблена в роботі [40]. Дослідження показали, що попередня інформація може бути включена в рамки ГЗМ. В циклічній ГЗМ, генератор представлений випадковим шумом z , а також деякою попередньою інформацією. Крім того, попередні знання

подаються до дискримінатора разом із відповідними реальними або штучними даними. Математично, умовна ГЗМ задається наступним чином:

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} \quad (2.1)$$

Виходячи з умов мереж було показано, що можна підвищити як стабільність навчання, так і генерацію вихідних даних (рисунок 2.2). У роботі [41], запропоновано вдалий варіант умовного ГЗМ для складного завдання відображення зображення на зображення. У цій архітектурі генератор та дискримінатор слідує за мережами U-Net [42] та мережами марківські ГЗМ (MGAN) [9], які демонструють добру основу для умовного перетворення. У запропонованій моделі функція втрат поєднується із “змагальними” втратами. Це більше впливає на генератор, щоб отримати штучні правдиві зображення на основі реальних зображень.

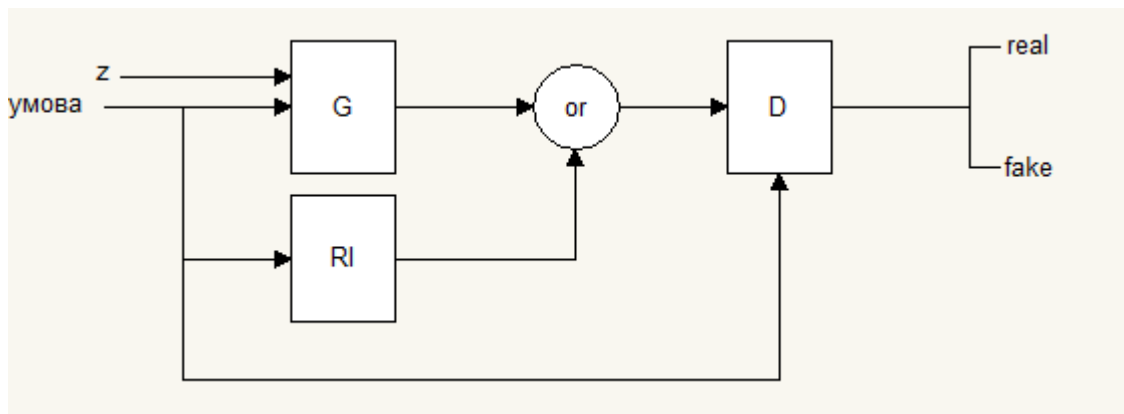


Рисунок 2.2 – Структура умовної генеративно-змагальної мережі

На рисунку 2.3 подано ще одна умовну ГЗМ - це марківська ГЗМ [9]. Марківська ГЗМ, як зображена на рисунку 2.3, активно використовується заздалегідь підготовлену мережу VGG19 з фіксованими вагами для отримання функцій високого рівня як для цільової текстури, так і для одночасного збереження вмісту зображення.[39]

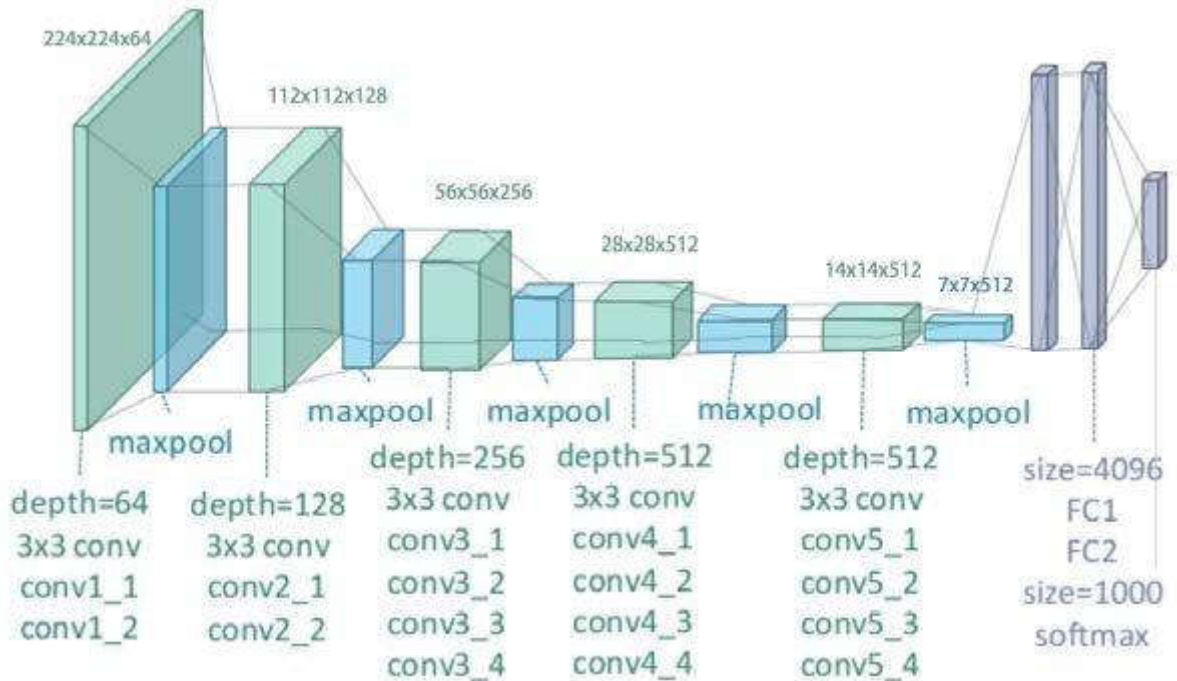


Рисунок 2.3 – VGG19 архітектура

Архітектура дискримінатора та генератора представлена мережею VGG19. Генератор передає карти зображень на зображення з цільовою текстурою, а дискримінатор перетворює або вхідне (дійсне або штучне) текстуризоване зображення у VGG19, що остаточно розмежовується за допомогою повністю згорткової мережі (FCN). Використання повної загорткової мережі (FCN) для класифікації вхідних даних як реальних або штучних в кінцевому результаті, означає класифікацію в просторі карти VGG19. Навчаючи генератор так, що він змушений генерувати зображення, які приводять до реалістичної функції VGG19 активації, як це було б отримано на реальних даних. Додатковий компонент перцептивних втрат (розрахований із використанням VGG) гарантує, що вміст зображення не змінюється.[39]




Рисунок 2.4 – марківська ГЗМ

2.2 Структури глибоко-згорткових генеративно-змагальних мереж

На рисунку 2.5 подано архітектуру ГЗМ, яка має на меті виявити базовий взаємозв'язок між двома областями зображення шляхом вивчення їхніх особливостей з непарних даних. Для досягнення цієї мети, створений алгоритм навчання циклу, використовується для основних особливостей доменного зображення для їх перетворення в інший домен. Оскільки функція карти, засвоєна змагальними втратами, не є надійною для відображення вхідного зображення на потрібний вихід, розглядається функція втрати циклу, щоб зменшити простір можливих функцій відображення. Таким чином два генератори ($G: X \rightarrow Y$ і $F: Y \rightarrow X$) вважають відображенням від X домену до домену Y і навпаки, а також два дискримінатори (D_Y і D_X) для їх навчання. Ця стратегія навчання стабілізує продуктивність мережі і створює високоякісні перетворені зображення. Визначена кінцева функція втрат наступним чином: [43]

$$L(G, F, D_x, D_y) = L_{GAN}(G, D_y, X, Y) + L_{GAN}(F, D_x, Y, X) + \lambda L_{cyc}(G, F) \quad (2.2)$$

$$L_{cyc}(G, F) = \mathbb{E}_{x \sim p_{data}(x)} [\|F(G(x)) - x\|_1] + \mathbb{E}_{y \sim p_{data}(y)} [\|G(F(y)) - y\|_1] \quad (2.3)$$

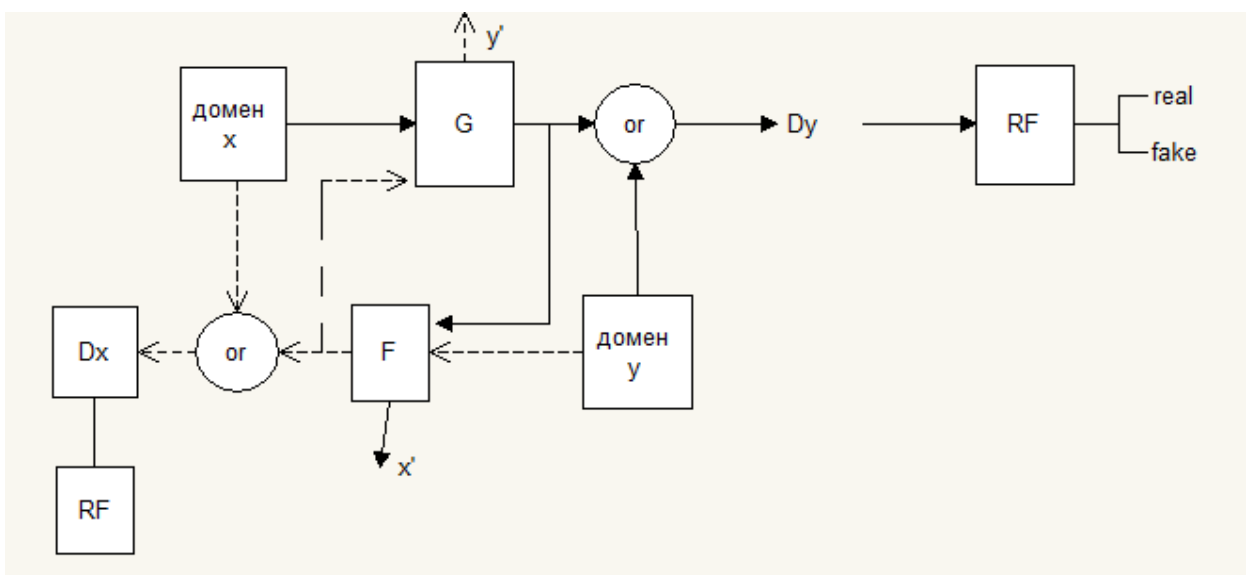


Рисунок 2.5 – Циклічні ГЗМ

На рисунку 2.6 подано архітектуру ГЗМ допоміжного класифікатора. Дискримінатор має реконструювати допоміжну інформацію. У ГЗМ допоміжного класифікатора архітектура дискримінатора модифікується таким чином, що після декількох шарів розбивається на стандартну вибіркочу дискримінаційну мережу (мережа допоміжних класифікаторів) , яка спрямована на класифікацію зразків на різні класи. Автори показують, що це дозволяє використовувати, частково, заздалегідь підготовлені дискримінатори і, як наслідок, стабілізувати навчання.[44]

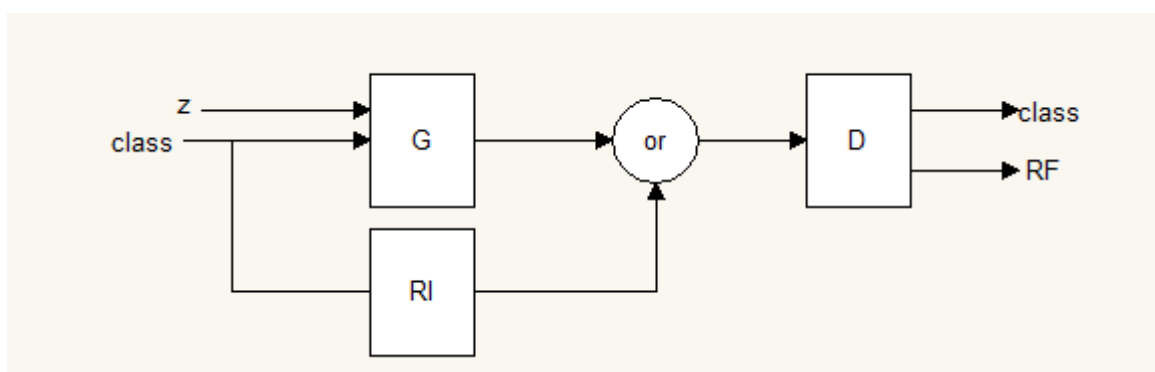


Рисунок 2.6 – ГЗМ допоміжного класифікатора

Для вирішення нестабільності архітектури ГЗМ в роботі [39], пропонують глибоко-згорткову ГЗМ (DCGAN) (рисунок 2.7) [40], в якій генератор і дискримінатор є глибокими згортковими мережами. Ці мережі здатні вилучати ієрархічні особливості зображення, вивчаючи вибірку вниз / вгору за рахунок локалізації ознак. Вилучені властивості об'єктів можуть бути використані, щоб генерувати нові зображення. Ключові компоненти (DCGAN) мережі здійснюють групову нормалізацію і є більш стійкими, ніж ГЗМ, але вони схильні до режиму колапсу.

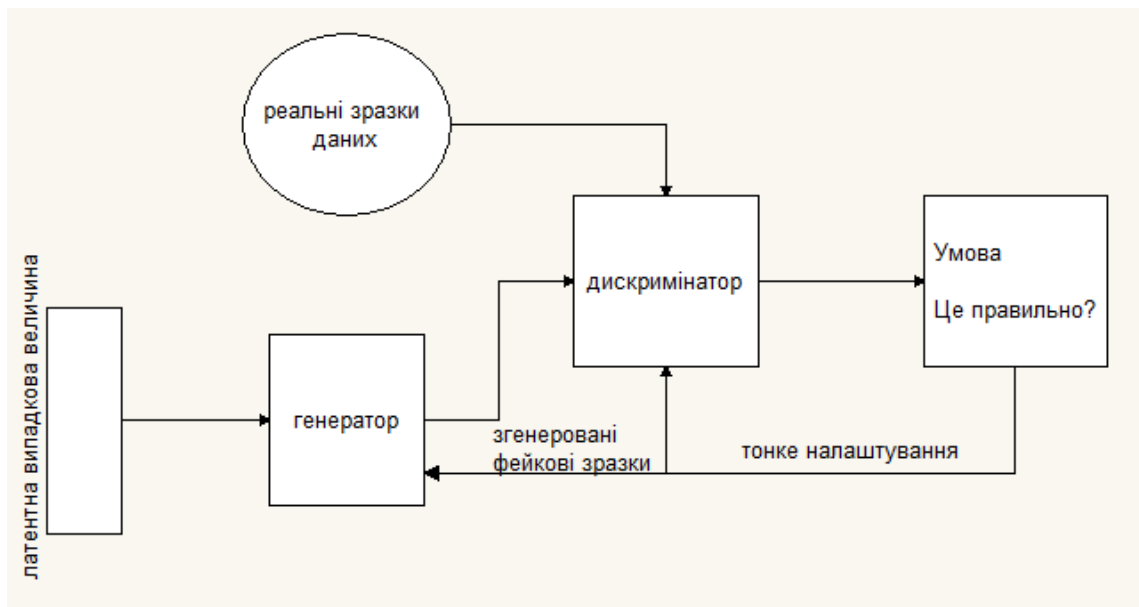


Рисунок 2.7 – Глибоко-згорткова ГЗМ

Отже, розглядаючи іншу, більш приблизну оцінку відстані між реальним та породженим розподіл даних може бути ефективним як рішення. "Арйовський та ін." [12] пропонують архітектура Вассерштейна ГЗМ (WGAN), яка використовує рухому землю (ME) або оцінка відстані замість розбіжності. На додаток, і генератор, і дискриміатор відповідають загальній архітектурі глибоко-згорнутої ГЗМ. Вассерштейн ГЗМ забезпечує надійну змагальну генеративну модель за допомогою більш змістовної процедури навчання, яка здатна знайти більш глибокі взаємозв'язки між розподілами. Незважаючи на ці теоретичні переваги, WGAN призводить до уповільнення процесу оптимізації в практичних сценаріях. [39]

2.3 Застосування структур генеративно-змагальних мереж для синтезу біомедичних зображень

Спочатку ГЗМ (GAN) були використаний як фреймворк, метою якого є реалістично відобразити випадковий шум на синтезований для розподілу тренувальних даних. З умовною ГЗМ, структура також була успішно перетворена в контрольовану генеративну структуру, зумовлюючи як

генератор, так і дискримінатор на генерування зображень. Генеративна властивість обох структур використовувалося в різних способи синтезу певних типів медичних зображень або з одного шуму, або з попередніх знань, такі як метадані або навіть дані зображення.

Останнім часом з'явилася велика кількість робіт, присвячених генерації медичних зображень з використанням ГЗМ. Синтез медичних зображень відкриває багато нових можливостей для розв'язання добре відомих проблем з навчанням, збільшення даних [41] або відсутність помічених даних. Крім того, це полегшує моделювання даних [45] і допомагає отримати більш глибоке розуміння природи розподілів даних і їх прихованої структури. Початкові результати показали, що ГЗМ можуть бути використані для реалістичного синтезу виглядають плями передміхурової залози [46] або зображення сітківки [17]. Обидва підходи покладаються на архітектуру глибоко-згорткової ГЗМ для синтезу патчів з роздільною здатністю 16×16 .

В роботі [45] автори успішно використовують глибоко-згорткову ГЗМ для генерації плям 56×56 пікселів на вузлах раку легенів, які навряд чи можна відрізнити від справжніх патчів в візуальному тесті Тьюринга за участю двох рентгенологів. [44] використовувати глибоко-згорткова мережа (DCGAN) для синтезу в КТ вогнища ураження печінки різних класів з роздільною здатністю 64×64 пікселів.

Для кожного класу зображень ГЗМ навчають окремо. Оскільки навчальний набір даних спочатку досить малий, вони використовують доповнені дані для навчання ГЗМ. У серії експериментів для печінки класифікації ушкоджень, автори демонструють, що синтетичні зразки на додаток до збільшення даних може значно поліпшити ЗНМ.

Робота в [46] показала, що глибоко-згорткова ГЗМ з навчанням, може навчитися імітувати розподіл даних МР в значно вищу роздільну здатність при невеликій кількості зразків. Реально розподіл даних складався тільки з 528 осьових МР-зрізів по середньої лінії T1 з роздільною здатністю 220×172 . Після навчання 1500 епох, автори отримали візуально переконливі результати, які

людські спостерігачі не могли достовірно розрізнити зі справжніх МР зрізів середньої лінії.

В роботі [47] автори використовують і порівнюють як глибоко-згортовка ГЗМ, ГЗМ з лапласіаном, так і їх модифікації для задачі синтезу ураження шкіри при роздільні здатності 256×256 пікселів. Як і в [48], навчальний набір даних був досить маленьким і складав з всього 1600 зображень. Ймовірно, через високу дисперсію, малої кількості зразків виявилось недостатньо для навчання надійної глибоко-згорткової мережі (DCGAN), однак ієрархічний ГЗМ лапласія LAPGAN і його варіанти показали хороші результати.

Синтетичні зразки також частково успішно використовується для збільшення даних при навчанні класифікатора ураження шкіри. В статті [49] ті ж автори використовували недавно запропоновану концепцію прогресивного нарощування ГЗМ для синтезу зображень уражень шкіри і показали дуже реалістичні синтетичні зображення, які навіть досвідчені дерматологи не могли достовірно відрізнити один від одного з реальних зразків.

У багатьох клінічних умовах КТ зображення є необхідними. Це, однак, ставить пацієнта під загрозу ураження клітин та раку через опромінення, яке мотивує синтез КТ-зображень. Синтезують зображення [50] КТ із відповідних 3D зображень за допомогою каскаду 3D повністю згорткових мереж, які вони тренують із нормальною втратою відновлення, втратою градієнта зображення та додатково з змагальною мережею для покращення реалістичності синтетичного КТ зображення. [51] Ідея використання каскаду генерувальних мереж бере свій початок так звана модель автоматичного контексту, в якій мережа забезпечує свій вихід як додатковий вклад до наступної мережі з метою надання контекстної інформації та доопрацювання (рисунок 2.8). Тоді як автори вимагають відповідних пари зображень КТ та МР для тренувань, [52] успішно використовувати циклічну ГЗМ (Cycle-GAN) для перетворення 2D-MPT-зображень у КТ-зображення. Автори [53] використали умовні ГЗМ, щоб зіставити дані 3D МРТ голови на її аналог КТ з метою полегшення сегментації черепно-лицьової кістки.

Модель VGG16 перевіряє реальні та синтетичні КТ зображення, надає оновлення градієнта до фактичної мережі генератора. Зазначимо, що дискримінатор використовує представлені карти різних рівнів мережі, що перевіряється так званим "глибоким наглядом". Успішно [54] використовуються циклічні ГЗМ [39] (CycleGAN) для непарного перетворення зображення в зображення. Автори показали що продуктивність моделі сегментації може бути покращена на 16%, коли додатково навчаються із синтетичними даними, і лише ті синтетичні дані є достатні для навчання моделі, яка виконує лише на 5% гірше, ніж модель навчені за реальними даними. Як недавно вказувалося, головне обмеження ГЗМ в роботі - відсутність гарантії наявності пухлин або уражень на зображенні зберігаються під час перетворення зображення на зображення. Циклічні ГЗМ (CycleGAN), запропонував додатково функцію втрати, спричиненої пухлиною до мети циклу-узгодженості для синтезу МРТ-зображень з пухлинами з КТ-зображення з пухлинами. Навчившись, вони спочатку збільшують свій малий тренувальний набір MR для навчання моделі сегментації пухлин.

Синтез зображень сітківки [44] автори використовують незначну модифікацію концепції змагальної підготовки, запропонованої в статті, для складного завдання синтезу очного дна. Вони вивчають відображення з бінарних зображень дерева судин до нових зображень сітківки з роздільною здатністю 512x512, які виглядають реалістично і дуже добре оцінюють якість зображення сітківки. У подальшій роботі [45] автори далі вводять автокодер, який навчається для стиснення зображень дерев суден у багатовимірному нормальному розподілі та послідовній їх реконструкції. Отриманий генеративний автокодер дозволяє синтезувати довільне дерево судин високої роздільної здатності зображення шляхом відбору проб з багатовимірного нормального розподілу. Синтетичні зображення, в свою чергу, в кінцевому рахунку подаються на модель перетворення зображення на зображення, що веде до створення реалістичного зображення сітківки з високою роздільною здатністю. Аналогічно, автори [30] пропонують двоступеневий підхід, що складається з ГЗМ, який навчається

синтезувати зображення дерев суден із шуму, і другий умовна ГЗМ, як показано в Pix2Pix [46], щоб генерувати реалістичні, з високою роздільною здатністю пар сегментації судин. Послідовно вони досліджують ефективність тренінгу U-Net для сегментації з використанням реальних пар даних та іншої моделі, що навчається лише на синтетичні зразки, і виявити, що навчання лише із синтетичних даних приводить до неповноцінних моделей.

У роботі [56] автори також використовують основу Pix2Pix для виконання завдань синтезу ниткоподібних структурованих зображень, тобто зображень очного дна та нейронів від бінарних сегментних масок. Опорне зображення для стилю та навчають генератор із зворотним зв'язком з додатковою VGG-мережею, що використовується для передачі стилю. і показують, що лише 10 прикладів навчання є достатніми для підготовки такої моделі перетворення зображення на зображення. На противагу Pix2Pix, вони роблять збільшення шуму, що є вузьким місцем мережі кодер-декодер. У наборі експериментів із застосуванням сегментації зображення сітківки продемонстровано, що введення додаткових синтетичних зображень, тобто навчання як із реальних, так і з синтетичних зображень, трохи покращує ефективність сегментації.

Зображення ПЕТ із КТ ПЕТ часто використовуються для діагностики в онкології, а комбіноване отримання зображень ПЕТ та КТ є стандартною процедурою в клініці. Крім того, ПЕТ / КТ зображення перетворюються на важливий інструмент оцінки нових медикаментозних методів терапії. Однак ПЕТ-пристрої включають радіоактивність і, таким чином, піддають ризику пацієнтів, і вони загалом дорогі.

Отже, спеціалісти з аналізу медичних зображень працювали над синтезом ПЕТ-зображень безпосередньо з даних КТ. У цьому контексті також ГЗМ показали хороші показники. Зображення ПЕТ із даних КТ із умовними ГЗМ були отримані в роботі [57]. Умовна ГЗМ, здатна синтезувати дуже реалістичні зображення, шукаючи ПЕТ-зображення, проте ціною низької реакції на недостатньо представлену ділянки пухлини, що приводить до поганих показників виявлення пухлини в наборі дослідницьких прикладів. На відміну від

цього, автори виявляють, що повна згорткова мережа (FCN) для синтезу ПЕТ-зображень здатний синтезувати пухлини, але створює розмиті зображення. Змішуючи відповідні синтетичні зображення ПЕТ, що надходять від умовного ГЗМ та повна згорткова мережа (FCN), вони можуть досягти дуже високого виявлення пухлини. Використовуються [39] умовна ГЗМ для синтезу ПЕТ-зображень розміром 200×200 пікселів з пар КТ-зображень. Лише зображення КТ були б достатніми в якості вхідних даних, вони зауважимо, що додавши мітку, яка позначає місце розташування пухлини, вони отримують глобально більш реалістичний синтетичний вихід. Через двоканальний вхід до генератора, вони називають свою мережу багатоканальною ГЗМ.

Далі автори підтвердили свої синтетичні ПЕТ-зображення за допомогою моделі виявлення пухлини навчився синтетичним даним і отримав порівнянні результати з тренованою моделлю з реальними даними, що показують, що синтетичні дані насправді можуть бути корисними, коли вони є - це відсутність мічених даних. Для моніторингу прогресування захворювання, розуміння фізіопатології та оцінки ефективності лікування розсіяного склерозу (MS), вимірювання вмісту мієліну в ПЕТ-зображеннях мозку людини останнім часом є дуже цінним. Автори [40] використовують каскад двох умовних ГЗМ (GAN) для синтезу таких ПЕТ-зображення із набору різних зображень МРТ. Їх підхід діє безпосередньо на об'ємних даних, використовуючи 3D U-Net для генераторних мереж і дискримінаційні мережі з тривимірними згортками. Цікаво, що автори зауважили, що однієї умовної ГЗМ було недостатньо для виконання завдання. Розщеплення задачі синтезу на менші, стабільніші підпроблеми, здавалося, різко покращили результати.

пропонують умовну архітектуру ГЗМ для синтезу [41] 2D-ультразвукових зображень фантома плода. На відміну від стандартного умовної ГЗМ, автори вважають за необхідне перетворення цього розташування пікселів у мапах функцій та з'єднання їх із створеними характеристиками карт на кожному рівні генератора для полегшення навчання. У своїх експериментах демонструють здатність імітувати зображення у місцях невидимих для мережі, кількісно

оцінювати генерування звукових зображень шляхом порівняння розташування клінічно значущих анатомічних орієнтирів у синтетичних та реальних зображення та перевірити реалістичність створених зображень у дослідженні. Кількісні результати показують, що анатомічні орієнтири грубо синтезовані при правильному місці із середньою помилкою 6,1 мм. У своєму дослідженні щодо зручності використаного сонографа зміг здебільшого правильно розрізнити реальне та породжене зразки, що обумовлено контрольними артефактами на синтетичних зображеннях. Після розмиваючи зображення за допомогою гауссового ядра з $\sigma = 1,5$, сонограф був не в змозі надійно сказати різницю. У роботі міститься умовна ГЗМ. [57] застосовуються ГЗМ для симуляції внутрішньосудинного ультразвуку (IVUS). Перший генератор, обумовлений фізично змодельованими картами тканин, створює рисунки з крапками, які, в свою чергу, виконують роль другого генератора на основі залишкової мережі. Другий генератор відображає вилучення зображень із низькою роздільною здатністю, синтетичні зображення розміром 64×64 пікселів. А третій генератор перетворює ці зображення низької роздільної здатності у зразки високої роздільної здатності з роздільною здатністю 256×256 пікселів. У візуальному тесті синтетичні зображення не можна було надійно відрізнити від реальних.

Рентген Махапатра та ін. [58] тренують умовні ГЗМ для синтезу рентгенографії грудної клітки із збурених карт сегментації та поєднують їх з байєсовою нейронною мережею для активного навчання. Точніше, вони пропонують невизначений підхід до вибору синтетичного зразка для тренування сегментації нейронних мереж на зразках, які є інформативними для цієї моделі.

Умовні ГЗМ також були використані для подолання дисперсії в цифровому гістопатологічному фарбуванні, що добре відомо викликають проблеми для САПР. Чо та ін. [39] зазначають, що класифікатор пухлини погано узагальнює обидві дані з фарбуючими властивостями, відмінними від навчального набору, а також на зображення, які були нормалізовані плямами найсучаснішими методами. Щоб подолати ці проблеми, вони пропонують функцію збереження

умовної ГЗМ (GAN) для передачі стилю плям з конкретною метою запобігання зменшення продуктивності систем САПР на синтетичних зображеннях.

По-перше, вони відображають гістологічні зображення на канонічне сіре зображення. Послідовно вони використовують умовної ГЗМ (GAN) для перетворення зображень сірого масштабу в зображення RGB з потрібним фарбуванням. Використовуючи додаткову функцію збереження, втрачені на прихованих шарах дискримінатора, вони демонструють, що пухлина виконує модель класифікатора, що навчається на даних, що впливають із певного розподілу. Умовна ГЗМ (GAN) показує найменше погіршення продуктивності порівняно з іншими сучасними методами перенесення плям.

Bayramoglu et al. [40] використовують Pix2Pix для віртуального фарбування H&E на незахищених гіперспектральних зображеннях мікроскопії, з роздільною здатністю 64×64 пікселів. Автори повідомляють, що між синтетично забарвленими образами та реальними є невелика різниця і зазначають, що вони отримали багатообіцяючий результат, але потрібні відгуки експертів, щоб зробити обґрунтований висновок.

BenTaieb et al. [41] спробували вирішити проблему перенесення плям за допомогою допоміжного класифікатора ГЗМ шляхом одночасного навчання умовної ГЗМ для передачі плям та конкретної мережі (тобто модель сегментації чи класифікації). Спільна оптимізація генератора, дискримінатора, а мережева мережа приводить генератора для створення зображень з відповідними функціями, збереженими для конкретної моделі та в цілому приводить до покращення нормалізації плям порівняно з іншими найсучаснішими методами. Однак сама реєстрація не є досконалою та є схильною до артефактів. Шабан та ін. [42] полегшують потребу в парних тренувальних даних та спільної реєстрації, використовуючи циклічну ГЗМ (CycleGAN) для завдання перенесення плям.

У широкому наборі експериментів на різних наборах даних вони показують візуально багато більш переконливі результати передачі плям, ніж попередні методи глибокого та неглибокого навчання. Крім того, вони також кількісно показують, як їх підхід суттєво зменшує зміщення домену. Моделі

навчання: класифікатор, який навчається для виявлення мітозу, забезпечує набагато краще результати класифікації зображень, перенесених прямою із запропонованим підходом, ніж на оригінальних даних, а також знову на інші способи передачі плям.

Умовні ГЗМ (GAN) [43] аналогічні в Pix2Pix для передачі між фазовим контрастом і диференційною завадою. Контрастні (DIC) мікроскопічні зображення працюють з двома дискримінаційними мережами. Генератор типу U-net підготовлений для синтезу зображень. Два різні дискримінатори тоді розрізняють пари зображень реального джерела та синтезованими зображеннями. У наборі якісних і кількісних оцінок вони класифікують їхній підхід із двома дискримінантами щодо структури Pix2Pix, яка використовує лише один дискримінатор. Вони повідомляють про покращені результати в показниках. Примітно, що автори становлять порівняльну ефективність останніх зіставлення деталей, вже наявних у зображеннях.

Методи аналізу, виявлені на основі машинного навчання кровоносних судин (атеросклеротична бляшка або стеноз) при коронарній КТ-ангіографії (ССТА) є потужними. Щоб вирішити відсутність мічених даних, Wolterink та ін. [44] пропонують синтезувати правдоподібні 3D форми судин за допомогою ГЗМ Васерштейна (Wasserstein GAN). Для полегшення синтезу у 3D при достатньо високій роздільній здатності автори генерують 1D параметризацію примітивів, що характеризують. Магнітно-резонансна ангіографія (MRA) також перетворилася на важливий інструмент візуалізації судинних структур, але часто вона не стикається зі стандартними протоколами. В [45, 46, 47] автори запропонувати так звану керовану ГЗМ для синтезу зображень MRA з T1 та T2-зважених МР-сканувань, що потенційно полегшує потребу в додатковому МР скануванні. Їх умовна, керована GAN поєднує генератор, подібний на ResNet PatchGAN-дискримінатор. У таблицях 2.1; 2.2; 2.3 наведено аналіз усіх представлених методів синтезу зображень. Зокрема, ми повідомляємо про метод, що містить основну архітектуру ГЗМ, модальності зображення, над якими працює конкретний метод, набори даних, які були використані та роздільна

здатність синтезованих зображень. Далі ми не повідомляємо про якість і кількісні результати з моменту їх отримання тому що 1) у багатьох випадках вони недоступні; 2) важко інтерпретовані 3) загалом навряд чи порівняні. Загалом, було багато цікавих підходів на основі ГЗМ як для безумовного, так і для умовного синтезу зображень. Однак часто обґрунтованість методу, що розглядається, сумнівна і потребує більш детальної розробки.

Наприклад, [56] у багатьох тестах на візуальне твердження досить легко відрізнити реальні та створені зображення [14, 15, 35] завдяки артефактам у синтетичних зразках, наприклад, добре відомий шаблон шахівниці. В роботах [35, 15] автори застосовують анізотропну або гаусову фільтрацію як до реального, так і до фальшивого зразка, перш ніж представити їх рейтингам [35, 15]. Інша проблема полягає в тому, що ГЗМ схильні до колапсного режиму, при якому модель здатна генерувати лише зразки, що впливають з одного або декількох режимів реального розподілу даних, в результаті чого дуже подібні синтетичні зразки. Особливо у працях [16] та [17], зразки виглядають досить подібними.

Незалежно від реалізму, вищезгадані праці показали, що ГЗМ (GAN) можна успішно використовувати для моделювання та збільшення даних у завданнях класифікації та сегментації. Як реалізм, артефакти в і специфічні властивості згенерованих зразків впливають на модель машинного навчання при їх використанні.

Таблиця 2.1: Безумовні ГЗМ для синтезу медичних зображень

Метод	Модальність	Бази даних	Розд. здатність
[16] Архітектура глибоко-згорткові ГЗМ	MRI Prostate Lesions	SPIE Prostate X Challenge 2016	16 x 16
[15] Архітектура глибоко-згорткові ГЗМ	CT Lung Concer Nodules	Lidc-IDRI	56 x 56

[14] Архітектура глибоко-згорткові ГЗМ	focal CT liver lesion patches	non-public	64 x 64
[18] Архітектура глибоко-згорткові ГЗМ	2D axial brain MR slices	Baltimore	220 x 172
[19,20] Архітектура глибоко-згорткових ГЗМ, ГЗМ Лапласія, PGAN.	Dermoscopic Imags of Skin Lesions	ISIC2017 & ISIC 2018	256 x 256

Таблиця 2.2: Умовні ГЗМ для синтезу медичних зображень

Метод	Модальність	Бази даних	Розд. здатність
[21] 3D-Автоконтекст FCN з втратою суперництва, втратою градієнта зображення і втратою l2	MP до КТ	ADNI і 22 непублічні пари зображень таза	н/а
[23] Архітектура циклічної ГЗМ	2D сагітальний мозок МРТ і КТ зрізи	Не-публічний	256 x 256
[24] Архітектура 3D умовної ГЗМ	MP до КТ	ADNI	154 x 184 x 149
[25] Архітектура циклічної ГЗМ	2D серцева MP ш. маска сегментації до КТ серця w.	Не-публічний	232 x 232

	маска сегментації		
[27] Архітектура Тумор-Аваре ГЗМ	КТ до МР	НСКЛК (архів зображень раку і неpubлічний)	256 x 256
[28,29] Архітектура ААЕ і Pix2Pix	2D бінарне зображення дерева судин до зображень сітківки	DRIVE, MESSIDOR	512 x 512
[46] Архітектура 3D умовної ГЗМ	вузлики в легенях 3D	LIDC	64 x 64 x 64
[30] Архітектура ГЗМ і Pix2Pix	2D бінарне зображення дерева судин до сітківки	DRIVE, MESSIDOR	512 x 512
[31] Архітектура Pix2Pix w. Стил ь Трансфер	мікроскопічний нейрон очного дна	DRIVE, STARE, HRF, NeuB ₁	512 x 512 і вище
[32] Архітектура Pix2Pix and FCN	2D 2D пухлина печінки КТ до ПЕТ	Не-публічний	n/a

Таблиця 2.3: Умовні ГЗМ для синтезу медичних зображень

Метод	Модальність	Бази даних	Розд. здатність
[33] Архітектура умовного мульті-каналу ГЗМ	КТ і Сегментація пар на ПЕТ зображення	ADNI і 22 неpubлічні пари зображень таза	n/a
[35] Архітектура просторово-умовної ГЗМ	2D US	Не-публічний, плід Привид	160 x 120
[37] Архітектура багатоступенева	моделюються тканинні карти для	IVUS виклик	256 x 256

умовної ГЗМ	2D внутрішньосудинних досліджень США		
[38] Архітектура умовної ГЗМ	Сегментація карти для синтетичних рентгенівських зображень	SCR ящик рентгенівської бази даних	512 x 512
[39] Архітектура умовна, яка зберігає передача стилю ГЗМ	цифрова Гістопатологія	CAMELYON16	n/a
[40] Архітектура Pix2Pix	Гіперспектральних мікроскопічне забарвлення H & E	Не-публічний	64 x 64
[41] Архітектура ГЗМ допоміжного класифікатора	цифрова Гістопатологія	MITOS- ATYPIA14 MICA116 Glas кидає виклик непублічному раку яєчника	250 x 250
[42] Архітектура циклічної ГЗМ	цифрова Гістопатологія	MITOS- ATYPIA14, Camelyon16	256 x 256
[43] Архітектура умовної ГЗМ з 2ма дискримінаторами	Disc & Phase Контрастова мікроскопія	Не-публічний	256 x 256
[44] Архітектура ГЗМ Вассерштейна	Геометричні параметри розширено від ККТА	Не-публічний	n/a

[45] Архітектура умовно-керований ГЗМ	MRA від T ₁ & T ₂ w. МРТ осьові зрізи	IXI Набір даних	n/a
---------------------------------------	---	-----------------	-----

"Мао та ін." пропонують інше рішення стабілізації ГЗМ. ГЗМ на основі найменших квадратів (LSGAN) [39]. У цій архітектурі є деякі параметри додано у функцію втрат, щоб уникнути зникнення градієнта. Таким чином, синтез даних, які дискримінуються як реальні, але знаходяться далеко від розподілу реальних. Також градієнт буде рівним нулю лише в тому випадку, якщо розподіл підроблених даних ідеально відповідає розподілу реальних даних. Функція втрати для найменших квадратів ГЗМ є визначається наступним чином:

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [D(x) - b^2] + \mathbb{E}_{z \sim p_z(z)} [D(G(z)) - a]^2 \quad (2.5)$$

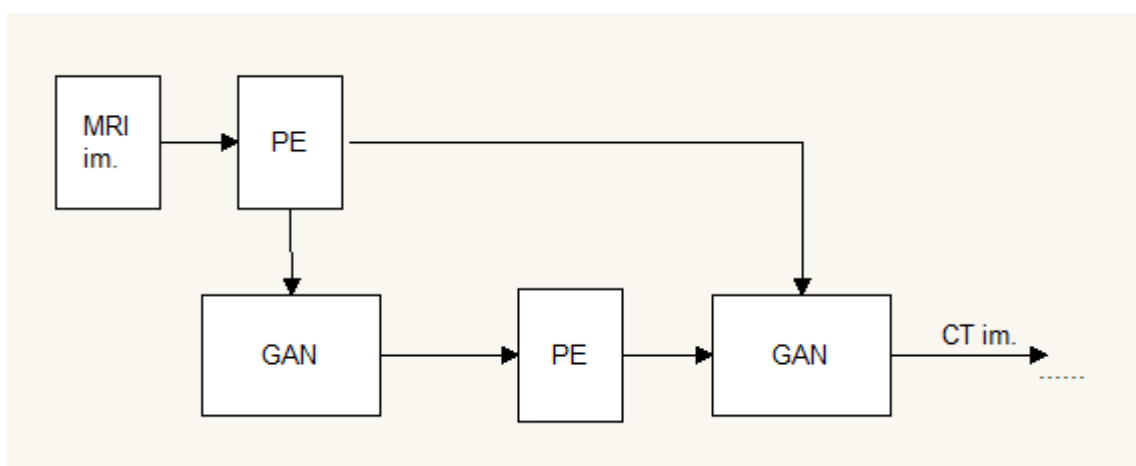


Рисунок 2.8 – ГЗМ з циклічними втратами для MRI зображень

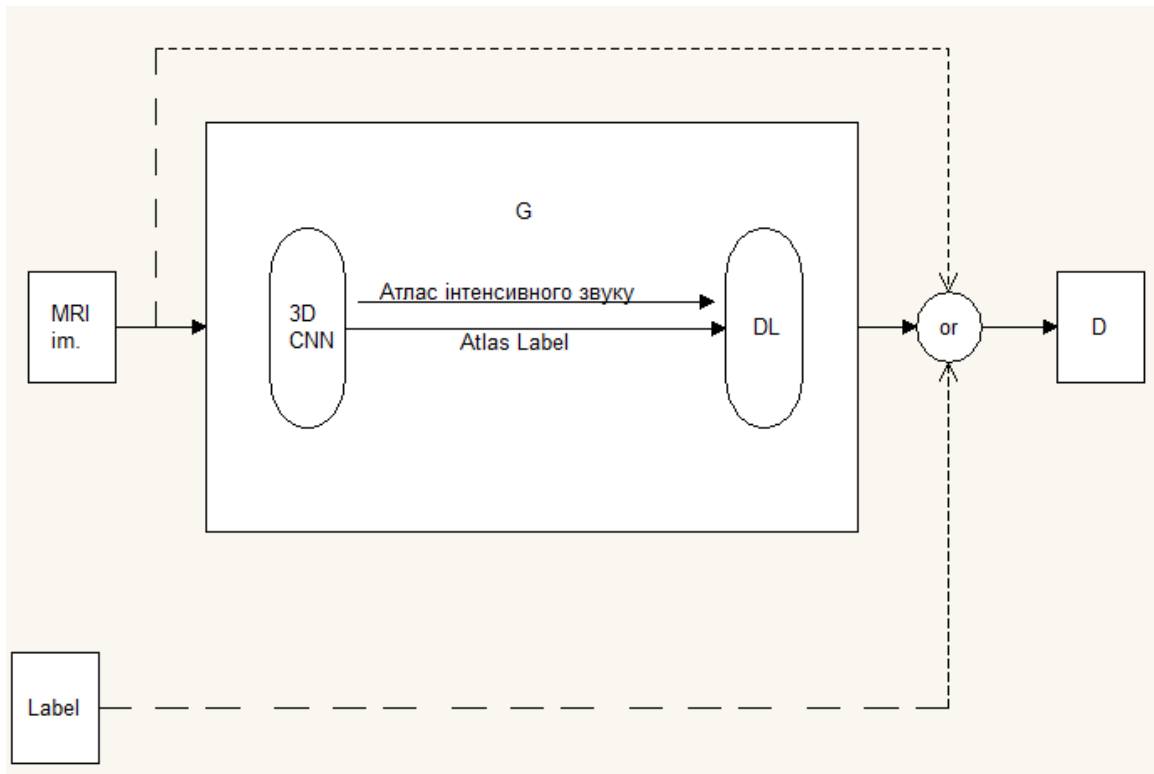


Рисунок 2.9 – 3D сегментація лівого шлуночка на ехокардіографії з керованою генерацією та дискримінацією

У багатьох клінічних умовах отримання КТ зображень є необхідним. На рисунку 2.9 подано зображення, яке ставить пацієнта під загрозу ураження клітин та раку через опромінення, яке вимагає синтезу КТ-зображень від отриманих МР зображень. Ніе та ін. [21] синтезують зображення КТ із відповідних 3D зображень за допомогою каскаду 3D повністю згорткових мереж, які вони тренуються із нормальною втратою відновлення, втратою градієнта зображення та додатково з змагальною мережею для покращення реалістичності синтетичного КТ зображення. Ідея використання каскаду генераторних мереж бере свій початок моделі автоматичного контексту, в якій мережа забезпечує свій вихід як додатковий вклад до наступної мережі з метою надання контекстної інформації та доопрацювання. Тоді як Ніе та ін. вимагають відповідних пар зображень КТ та МР для тренувань, у роботі [23] успішно використовують циклічні ГЗМ для перетворення 2D-МР-зображень у КТ-зображення без необхідності парних зображень. Чжао та ін. [24] використали умовні ГЗМ, щоб

зіставити дані 3D MR голови на її аналог КТ з метою полегшення сегментації черепно-лицьової кістки.

Результати робіт, які пропонують так звану "глибоку наглядну дискримінацію", як і перцептивна втрата, використовують представлення ознак перевіреної модель VGG16 для 1) представлення реальних та синтетичних зображень на КТ і 2) надають оновлення градієнта до фактичної мережі генератора. Зазначимо, що дискримінатор використовує представлені карти різних рівнів мережі, що перевіряється названий "глибоким наглядом" ГЗМ від КТ, подібного до результатів у роботах [33], [35].

Для синтезу пари кардіохірургічних зображень потрібна сегментаційна маска від пар серцевих КТ фрагментів. Продуктивність моделі сегментації може бути покращена на 16%, коли додатково навчаються із синтетичними даними, і лише ті синтетичні дані є достатніми для навчання моделі, яка виконує лише на 5% гірше, ніж модель навчена за реальними даними. Як вказувалося, головне обмеження ГЗМ в роботі [36] - відсутність гарантії наявності пухлин або уражень на зображенні зберігаються під час перекладу зображення на зображення. Щоб впоратися з цим питанням Jiang та ін. [37] запропонували додатково функцію втрати, спричиненої пухлиною з метою циклу-узгодженості для синтезу MR-зображень з пухлинами із КТ-зображення з пухлинами. Навчившись, вони спочатку збільшують свої малі набори тренувань MR для навчання моделі сегментації пухлин на основі та показують значні поліпшення, які показані на рисунку 2.10.

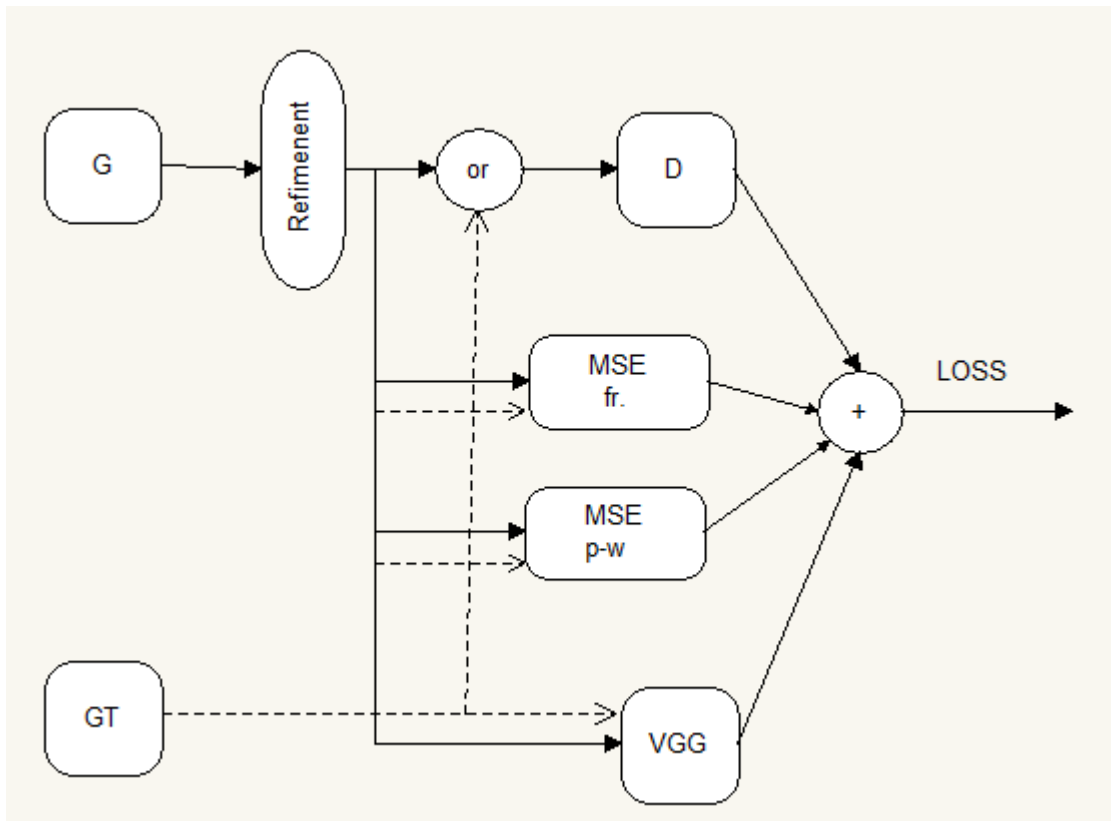


Рисунок 2.10 – DAGAN архітектура

У методі (V-Net [58]), спочатку форму та інтенсивність атласу оцінюється ЗНМ а потім мережею деформації виводиться сегментоване зображення (рисунок 2.10). Обидві згадані мережі поміщені в генератор, який поєднує три функції втрат для тренування: 1) змагальний збиток; 2) втрати інтенсивності та 3) втрати мітки, що порівнює інтенсивність і форму сегментованого реального зображення із створеним відповідно. Оскільки в сегментації, крім RoI є залишкова (не-RoI) інформація функції можуть зробити результати сегментації більш реалістичними, [59]. Джойс та ін. [50] пропонують скористатись залишковою інформацією, визначивши збитки на її основі. В обох роботах вхідне зображення реконструюється з RoI та залишкового витягнуті функції та втрати від реконструкції розглядаються на додаток до змагальних втрат. Чартіас та ін. [59] пропонують використовувати архітектуру циклічної ГЗМ для напівконтрольної сегментації та [50] пропонують архітектуру ГЗМ найменших квадратів для неконтрольованої сегментації. Більше того, пропонується уникати ще двох втрат надсегментації та великої дисперсії інтенсивності в сегментованих регіонах.

Для сегментації кількісно точного інфаркту міокарда Ху та ін. [51] ввели архітектуру на базі ГЗМ (MuTGAN), яка може отримати користь з усіх часових послідовностей кадрів інформації для сегментування зараженої області.

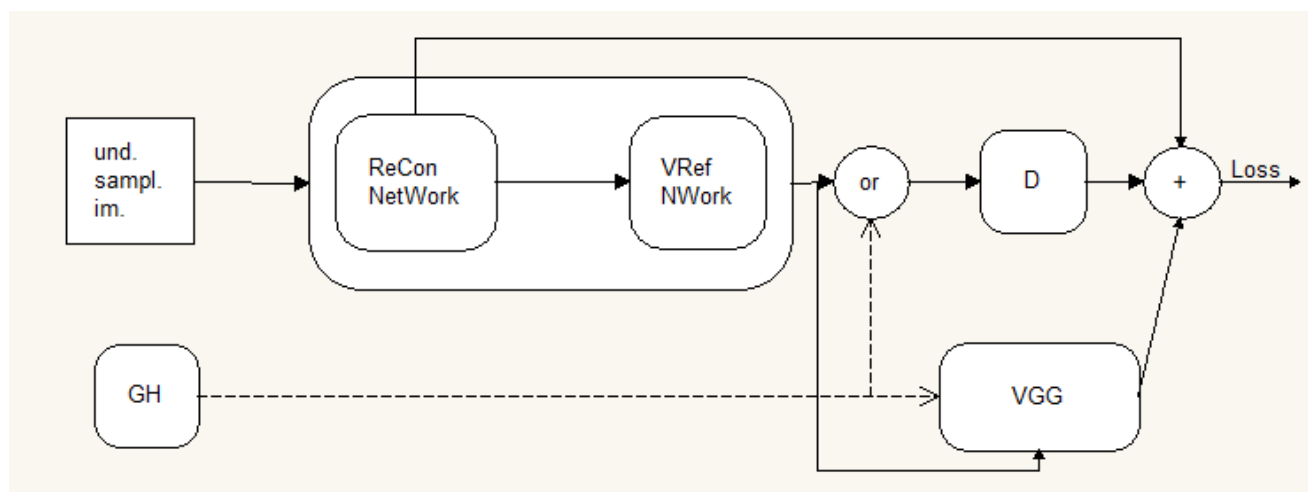


Рисунок 2.11 – DAGAN архітектура з уточнюючим шаром

Ранні дослідження реконструкції МР на основі ГЗМ зосереджуються на архітектурі (DAGAN) [56]. Роботи удосконалюють архітектуру глибоко-згладжувальних генеративно - змагальних мереж час [55, 56], одночасно уточнюючи комбінацію функцій втрат, яка працює найкраще

Ці функції втрат включають змагальну втрату, перцептивну втрату та частоту, що призводить до комбінованої функції втрат:

$$L_G = \alpha L_{image-MSE} + \beta L_{freq-MSE} + \gamma L_{VGG} + L_{GAN} \quad (2.6)$$

Наступне оновлення глибоко-згладжувальних генеративно – змагальних мереж (DAGAN) - введений шар удосконалення [57] разом із комбінацією чотирьох втрат, як показано нижче:

$$L_{ref} = \frac{1}{2} \left(\frac{L_{adv}}{M} + \frac{L_{feat}}{N} \right) + \frac{L_{VGG}}{O} + \alpha L_{pen} \quad (2.7)$$

де L_{feat} є функцією, яка відповідає втратам, запропонованим у [58], а L_{pen} - це штраф змусити мережу маніпулювати результатом оптимізованої із значенням (MSE) мережі з найменшими змінами, подібними на втрати, використані в (DAGAN). Аналогічну конструкцію архітектури генератора (рис. 11) також пропонує Quan та ін. [42]. Однак їх циклічна стратегія навчання призводить до ще двох втрат показано на наступному:

$$L_G = L_{adv} + \alpha L_{freg} + \beta L_{imag} \quad (2.8)$$

3D-конвуляційні блоки також розглядаються для реконструкції MR. [49], адаптовані в роботі [50] з 3D-згортковими шарами, щоб мати справу з об'ємною інформацією. Їх функція втрат поєднує в собі піксельну втрату з градієнтом.

Проблема великого обсягу пам'яті 3D-згортки вирішується Chen et al. [52]. Запропонована ними мережа поєднує в собі [53] багаторівневу щільну мережу суперроздільної здатності для швидкої реконструкції.

Для реконструкції томографії, [54] пропонують разом з комбінацією чотирьох різних генераторних втрат для реконструкції томографічних 3D-зображень. Окрім змагальних ще два інші функції втрат визначені для подолання надмірної інтерполяції та контролю даних.

Аналогічну конструкцію архітектури генератора, що подано на рисунку 2.12, також пропонує Quan та ін. [52]. Однак їх циклічна стратегія навчання призводить до ще двох втрат показано на наступному:

$$L_G = L_{adv} + \alpha L_{freg} + \beta L_{imag} \quad (2.9)$$

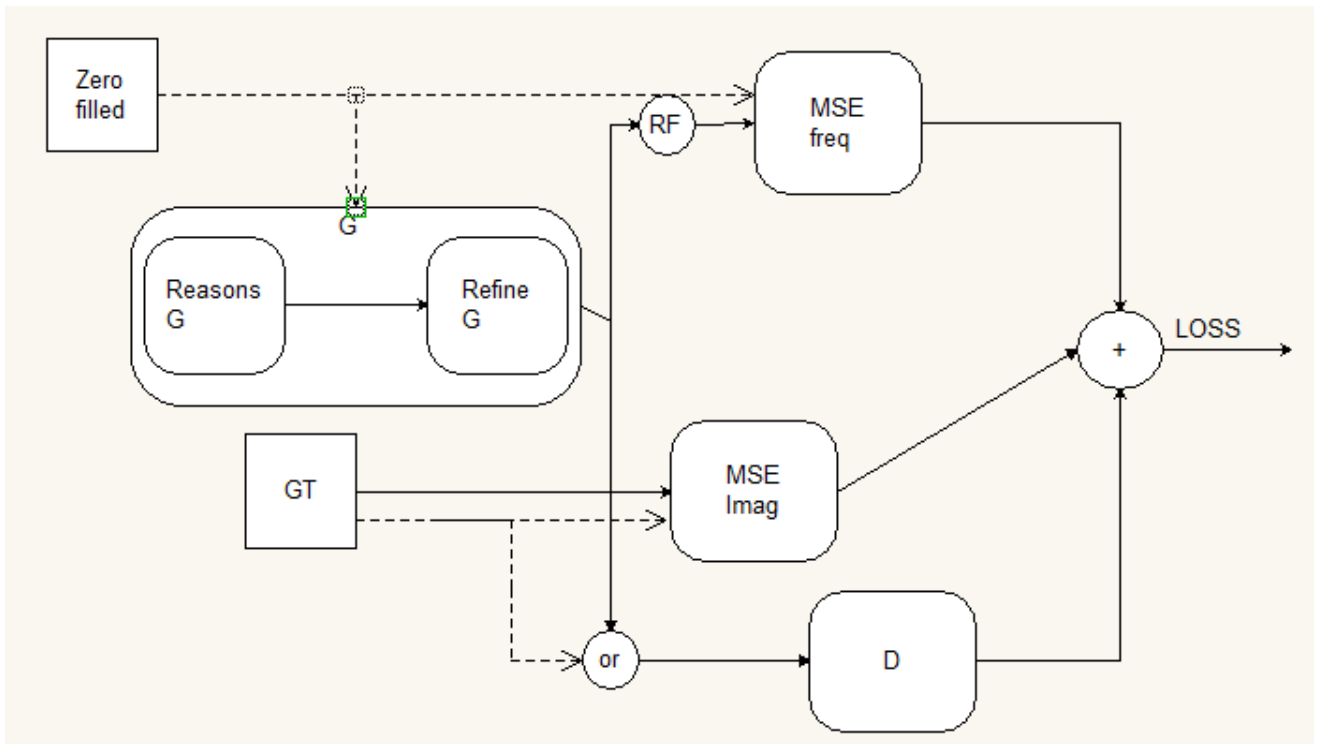


Рисунок 2.12 – Архітектура RefineGAN

Набуття зображення декількох форм діагностичної рентгенології передбачає компроміс між контрастною та радіаційною безпекою. Кращий контраст може привести до кращої діагностики, але може піддавати пацієнта небажаному надмірному опроміненню (рисунок 2.13).

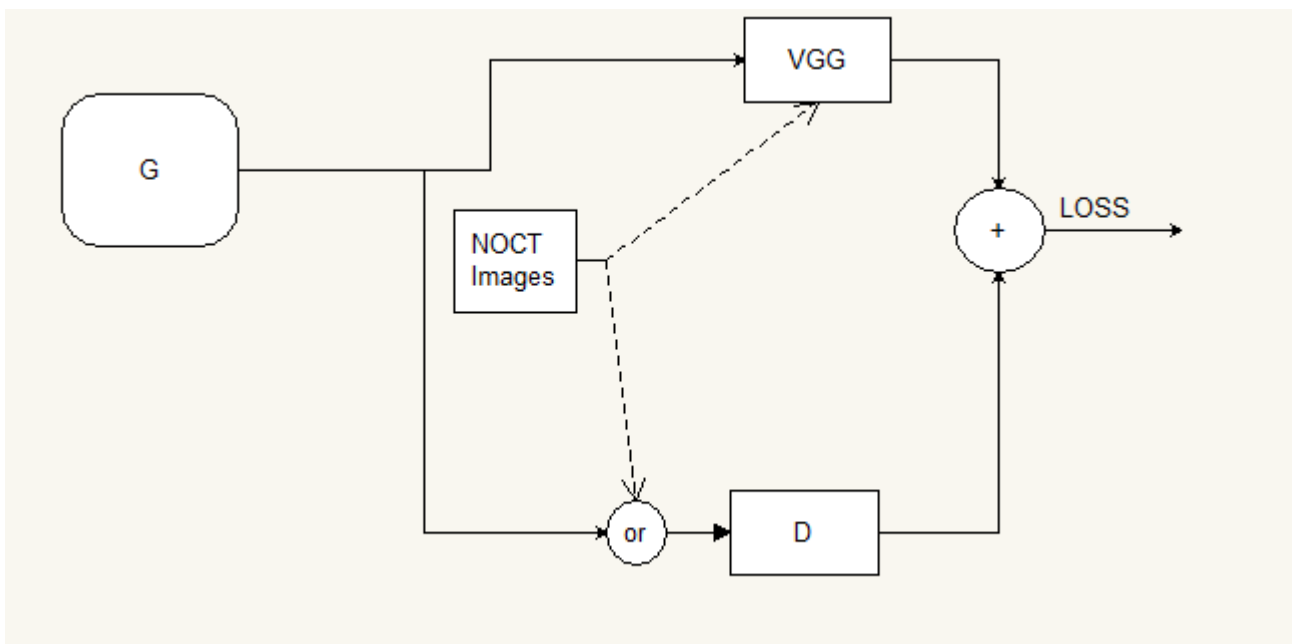


Рисунок 2.13 – Архітектура зображень ГЗМ без шуму

створені та реальні образи, але й класифікує зображення на два класи: ті, що є базальним зрізом чи ні, що подано на рисунку 2.15. Для класифікації простатиту до двох ступенів [59, 61] пропонують ГЗМ з витягнутими фіксованими функціями кожного домену, а потім використовувуть їх для класифікації. Через відсутність адекватних властивостей медичних зображень, ГЗМ генерує потрібні зразки.

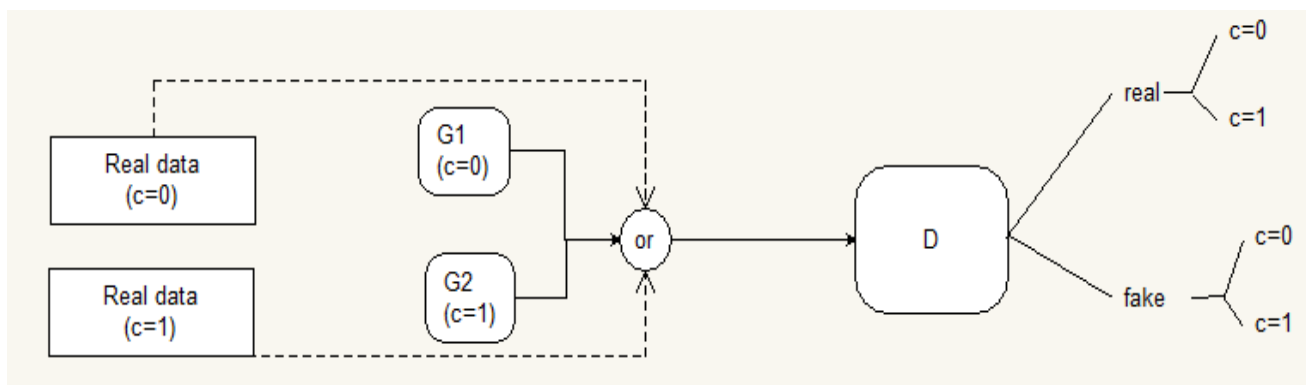


Рисунок 2.15 – Оцінювання неповного покриття за допомогою генеративних змагальних мереж

ГЗМ приділяють значну увагу з боку медичної спільноти із зображеннями - це очевидно через раптовий сплеск кількості публікацій, опублікованих із використання ГЗМ. "Генеративні змагальні мережі", [39, 62] запропоновано в синтетичних додатках. Однак поля додатків досить різноманітні, починаючи від сегментації, реконструкції, показуючи можливі програми ГЗМ через багато медичних завдань. [63]

У своєму початковому формулюванні ГЗМ не мали змоги зіставити дані спостереження. Запропоновано декілька методів інвертування генератора перетренованих ГЗМ [37], [38]. Незалежно запропонований конкурентно навчений висновок [39] і двонаправлений ГЗМ [40] забезпечують прості, але ефективні розширення, запровадження мережі висновку, в якій знаходяться дискримінатори досліджують спільні (дані, латентні) пари. [64]

У цій постановці генератор складається з двох мереж: «кодер» (мережа виводу) і «декодер». Вони спільно навчаються обманювати дискримінатора.

Дискримінатор сам приймає пари (x, z) векторів (рисунок 2.16), і має до визначити, яка пара є справжній кортеж, що складається з реального зображення та його кодування, або підробленого зображення і відповідний вхід латентного простору в генератор.[65]

В ідеалі, в моделі кодування-декодування, висновок, згаданий щоб як реконструкція, повинна бути подібна на вхідну. Як правило, првильність реконструйованих зразків даних, що синтезується використанням ALI / BiGAN є поганими. Правильність зразків може удосконалюватися з додатковою суперечливістю витрат на розподіл зразків даних та їх реконструкцій [66].

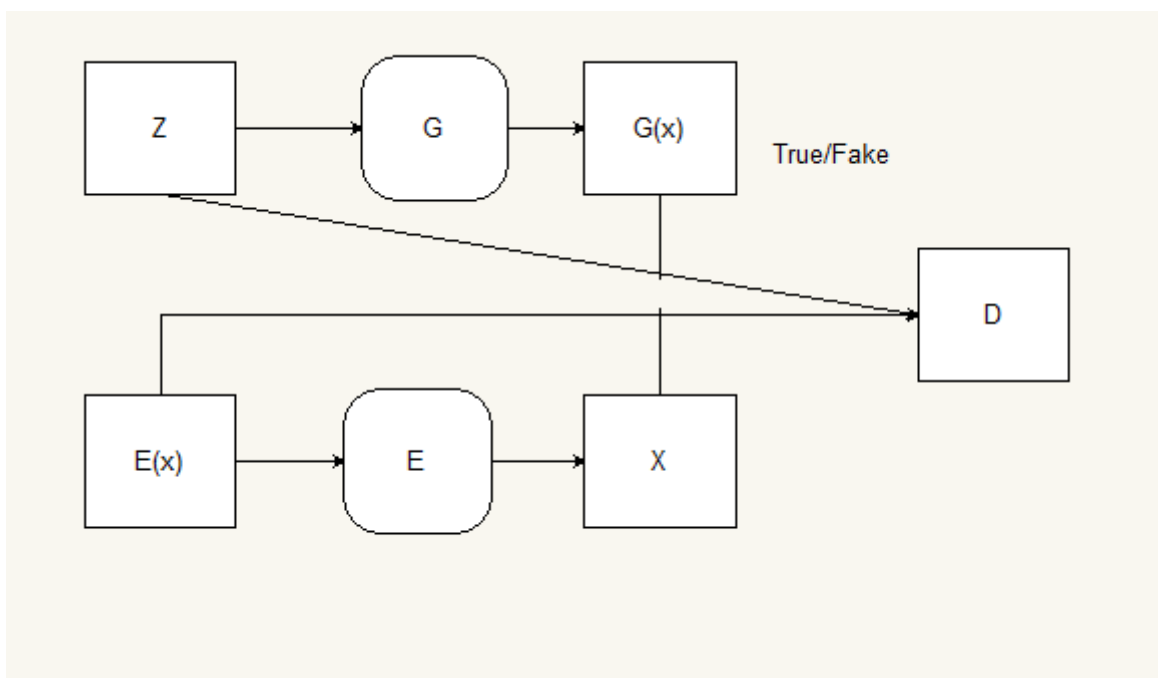


Рисунок 2.16 - Архітектура BiGAN / ALI

Автокодери є мережами, що складаються з кодера і декодера, які вчатья відображати дані на внутрішнє приховане представлення і знову виходити. Тобто вони вивчають детерміноване відображення (через кодер) з простору даних, наприклад, зображень, у простір прихованого або представлення, а також відображення (через декодер) від прихованого простору назад до простору даних. Ці два відображення приводять до реконструкції, а два відображення підготовлені таким чином, що реконструйоване зображення є такими, як близьким до оригіналу[61, 66].

3 ПРОГРАМНА РЕАЛІЗАЦІЯ МОДУЛЯ СИНТЕЗУ ЗОБРАЖЕНЬ

3.1 Структура програмного модуля

Об'єктно-орієнтоване програмування відноситься до типу комп'ютерного програмування (проектування програмного забезпечення), в якому програмісти визначити тип даних про вигляді структури даних , а також типи операцій (функцій), які можуть бути застосовані до структури даних. [67]

Об'єктно-орієнтоване програмування базується на таких принципах:

Інкапсуляція - реалізація та стан кожного об'єкта знаходяться в приватному порядку всередині визначеного межа, або клас. Інші об'єкти не мають доступу до цього класу або повноважень на внесення змін, але можуть лише викликати список загальнодоступних функції, або методи. Ця характеристика приховування даних забезпечує більш високу безпеку програми та дозволяє уникнути випадкової корупції даних .

Абстракція - Об'єкти розкривають лише внутрішні механізми, що мають відношення до використання інших об'єктів, приховуючи зайвий код реалізації. Ця концепція допомагає розробникам вносити зміни та доповнення з часом простіше.

Спадкування - можуть бути призначені відносини та підкласи між об'єктами, що дозволяє розробникам повторно використовувати загальну логіку, зберігаючи унікальну ієрархію. Ця властивість ООР примушує більш ретельний аналіз даних, скорочує час розробки та забезпечує більш високий рівень точності.

Поліморфізм - Об'єктам дозволено приймати більше однієї форми залежно від контексту. Програма визначає, яке значення або використання потрібно для кожного виконання цього об'єкта, скорочуючи необхідність дублювання коду.

Однією з головних переваг об'єктно-орієнтованих методів програмування перед процедурними методами програмування є те, що вони дозволяють програмістам створювати модулі , які не потрібно міняти, коли додається новий

тип об'єкта. Програміст може просто створити новий об'єкт, який успадковує багато своїх функцій від існуючих об'єктів. Це полегшує модифікацію об'єктно-орієнтованих програм. [67]

Java – досить поширена мова програмування, спеціально розроблена для використання в розподіленому середовищі Інтернету. Це найпопулярніша мова програмування для додатків для смартфонів Android, а також є однією з найбільш прихильних для розвитку крайових пристроїв та Інтернету речей . [69]

Java була розроблена таким чином, щоб мати вигляд мови програмування C ++ , але вона простіша у використанні та застосовується у об'єктно-орієнтованій моделі програмування . Java використовується для створення повноцінних програм, які можуть працювати на одному комп'ютері або розповсюджуватися між серверами та клієнтами в мережі. Він також може бути використаний для створення невеликого модуля програми чи аплету для використання у складі веб-сторінки.

Deeplearning4j - бібліотека програм на мові Java, яка використовується як фреймворк для глибокого навчання. Включає реалізацію обмеженою машини Больцмана, глибокої мережі довіри, глибокого автокодіровщика, стекового автокодіровщика з фільтрацією шуму, рекурсивної тензорною нейронної мережі, word2vec, doc2vec, and GloVe. Ці алгоритми включені також у версії бібліотеки, що підтримують розподілені обчислення, інтегровані з архітектурою Apache Hadoop і Spark.

Deeplearning4j реалізована на мові Java і виконується в середовищі, при цьому сумісна з Clojure і включає інтерфейс (API) для мови Scala. Додаткова бібліотека ND4J відкритого доступу забезпечує обчислення на графічних процесорах з підтримкою CUDA. Крім того, є засоби для роботи з бібліотекою мовою Python через фреймворк Keras.

Фреймворк дозволяє комбінувати компоненти, об'єднуючи звичайні нейронні мережі з машинами Больцмана, свёрточними нейронними мережами, автокодіровщиками і рекурентними мережами в одну систему. Крім того,

підтримуються розширені засоби візуалізації. Навчання проводиться як за допомогою звичайних багаточарових нейронних мереж, так і для складних мереж, в яких визначено граф обчислення.

Основні етапи налаштування Deeplearning4j:

1) Інсталяція Java. Java — об'єктно-орієнтована мова програмування, випущена 1995 року компанією «Sun Microsystems» як основний компонент платформи Java. З 2009 року мовою займається компанія «Oracle», яка того року придбала «Sun Microsystems». В офіційній реалізації Java-програми компілюються у байт-код, який при виконанні інтерпретується віртуальною машиною для конкретної платформи.

Приклад команди для перевірки версії java в консолі:

```
java -version
```

2) Налаштування Apache Maven. «Apache Maven» — це засіб автоматизації роботи з програмними проектами, який спочатку використовувався для Java проектів. Використовується для управління (management) та складання (build) програм. Для опису програмного проекту який потрібно побудувати (build), Maven використовує конструкцію відому як Project Object Model (POM), залежності від зовнішніх модулів, компонентів та порядку побудови. Виконання певних, чітко визначених задач — таких, як компіляція коду та пакетування відбувається шляхом досягнення заздалегідь визначених цілей (targets). Сторінку завантаження Apache Maven наведено на рисунку 3.1.

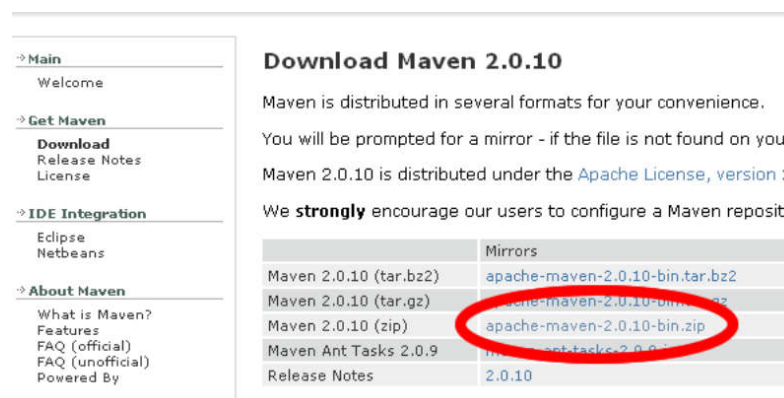


Рисунок 3.1 - Сторінка завантаження Apache Maven

Приклад команди для перевірки версії maven:

```
mvn --version
```

- 3) Налаштування git. Git — розподілена система керування версіями файлів та спільної роботи. Проект створив Лінус Торвальдс для управління розробкою ядра Linux, а сьогодні підтримується Джуніо Хамано (англ. Junio C. Hamano). Git є однією з найефективніших, надійних і високопродуктивних систем керування версіями, що надає гнучкі засоби нелінійної розробки, що базуються на відгалуженні і злитті гілок. Для забезпечення цілісності історії та стійкості до змін заднім числом використовуються криптографічні методи, також можлива прив'язка цифрових підписів розробників до тегів і комітів. Перелік команд для створення нового репозиторію наведено на рисунку 3.2.

```
$ cd <path_project> #Шлях до проекту (наприклад: $ cd c:/www/git). Переходимо в існуючу папку, в якій буде розміщений проект
$ git init #Ініціалізація репозиторію. Створює в каталозі Project каталог .git і в ньому всі необхідні файли репозиторію
$ git add . #Додаємо всі файли, які наявні в каталозі Project, під версійний контроль
$ git commit -m "Коментар" #Фіксуємо зміни
```

Рисунок 3.2 - Перелік команд для створення нового репозиторію

- 4) Завантаження бібліотеки Deeplearning4j. Для завантаження необхідно виконати наступні команди:

```
$ git clone https://github.com/eclipse/deeplearning4j-examples.git
$ cd dl4j-examples/
$ mvn clean install
```

- 5) Завантаження IntelliJ IDEA та імпорт проекту (рисунок 3.3).

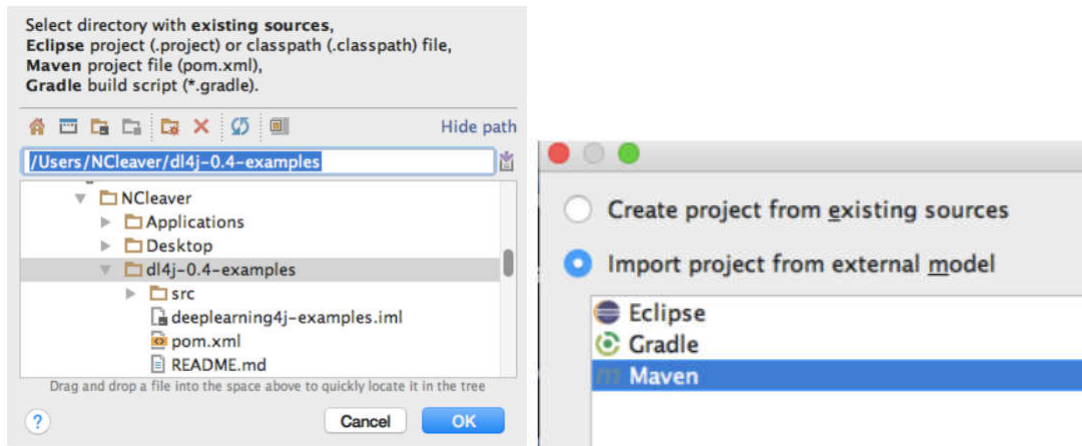


Рисунок 3.3 - Завантаження IntelliJ IDEA та імпорт проекту

б) Структуру проекту наведено на рисунку 3.4

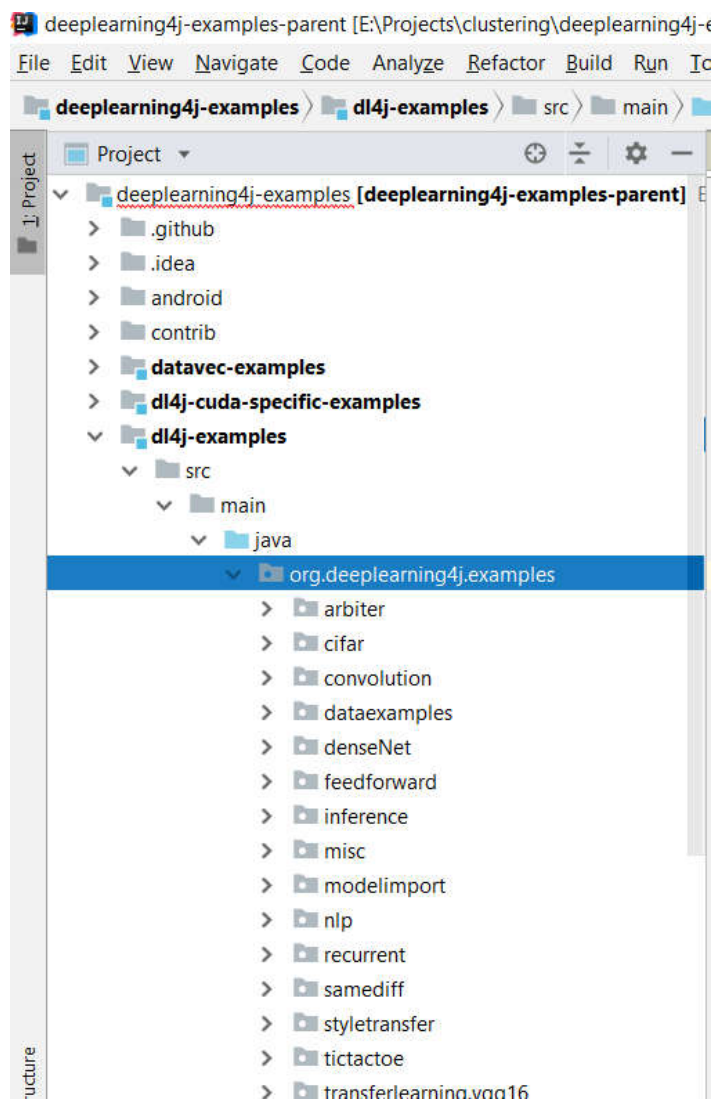


Рисунок 3.4 – Структура проекту

Поля та методу класу для реалізації класифікації з допомогою CNN наведено на рисунку 3.5.




Рисунок 3.5 - Поля та методу класу для реалізації класифікації з допомогою CNN

«main()» - метод, що відповідає за запуск програми, точка входу в систему.

«log» - призначений для логування подій, пов'язаних із роботою даного класу. Надалі таке логування дозволить знайти і вирішити причину помилок.

UML – діаграму модулю для класифікації зображень наведено на рисунку 3.6.

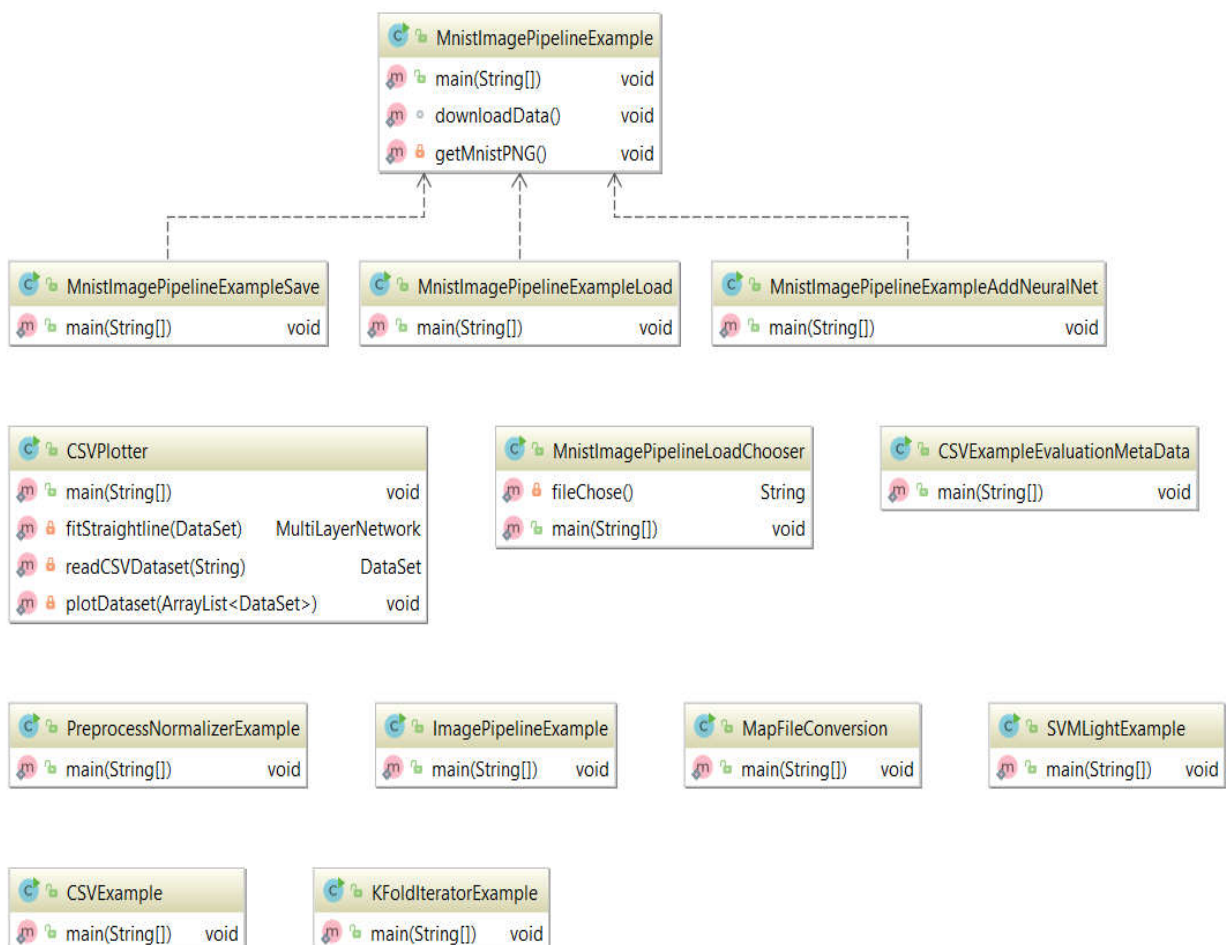


Рисунок 3.6 - UML – діаграму модулю для класифікації

Лістинг програмного коду класу для навчання згорткової нейронної мережі:

```
public class LenetMnistExample {
    private static final Logger log = LoggerFactory.getLogger(LenetMnistExample.class);

    public static void main(String[] args) throws Exception {
        int nChannels = 1; // Number of input channels
        int outputNum = 10; // The number of possible outcomes
        int batchSize = 64; // Test batch size
        int nEpochs = 1; // Number of training epochs
        int seed = 123; //

        /*
         * Create an iterator using the batch size for one iteration
         */
        log.info("Load data...");
        DataSetIterator mnistTrain = new MnistDataSetIterator(batchSize,true,12345);
        DataSetIterator mnistTest = new MnistDataSetIterator(batchSize,false,12345);

        /*
         * Construct the neural network
         */
        log.info("Build model...");

        MultiLayerConfiguration conf = new NeuralNetConfiguration.Builder()
            .seed(seed)
            .l2(0.0005)
            .weightInit(WeightInit.XAVIER)
            .updater(new Adam(1e-3))
            .list()
            .layer(new ConvolutionLayer.Builder(5, 5)
                //nIn and nOut specify depth. nIn here is the nChannels and nOut is the number of
                filters to be applied
                .nIn(nChannels)
                .stride(1,1)
                .nOut(20)
                .activation(Activation.IDENTITY)
                .build())
            .layer(new SubsamplingLayer.Builder(PoolingType.MAX)
                .kernelSize(2,2)
                .stride(2,2)
                .build())
            .layer(new ConvolutionLayer.Builder(5, 5)
                //Note that nIn need not be specified in later layers
                .stride(1,1)
                .nOut(50)
                .activation(Activation.IDENTITY)
                .build())
            .layer(new SubsamplingLayer.Builder(PoolingType.MAX)
                .kernelSize(2,2)
```

```

        .stride(2,2)
        .build()
    .layer(new DenseLayer.Builder().activation(Activation.RELU)
        .nOut(500).build())
    .layer(new
OutputLayer.Builder(LossFunctions.LossFunction.NEGATIVELOGLIKELIHOOD)
        .nOut(outputNum)
        .activation(Activation.SOFTMAX)
        .build())
    .setInputType(InputType.convolutionalFlat(28,28,1)) //See note below
    .build();

```

У даному випадку метод «layer()» відповідає за роботу одного з шарів згорткової нейронної мережі.

«nChannels» - кількість вхідних каналів;

«nEpochs» - кількість епох;

«MultiLayerConfiguration» - екземпляр класу класифікації зображень. Володіє методами для побудови нейронної мережі;

«ConvolutionLayer.Builder» - екземпляр класу, що реалізує згортковий шар нейронної мережі;

«SubsamplingLayer.Builder(PoolingType.MAX)» - екземпляр класу, що реалізує дискретизуючий шар згорткової нейронної мережі;

«kernelSize» - розмір вікна;

«setInputType» - метод , відповідальний за запуск повнозв'язного шару нейронної мережі, тобто реалізації багат шарового перцептронну.

3.2 Архітектура згорткової нейронної мережі

Приклади зображень наведено у таблиці 3.1.

Таблиця 3.1 - Приклади цитологічних і гістологічних зображень

Цитологія			
мастопатія	кістозна мастопатія	непроліферативна	фіброаденома

		мастопатія	
Гістологія			
листовидна мастопатія	фіброзно-кістозна мастопатія	непроліферативна мастопатія	фіброаденома

Як видно з таблиці 3.1 зображення поділено на 4 класи, що характеризують певний тип патологій.

Структуру існуючих моделей для класифікації зображень наведено на рисунку 3.7 (Зг – згортковий шар, С – суб дискретизуючий, П – повнозв’язний).



а) AlexNet

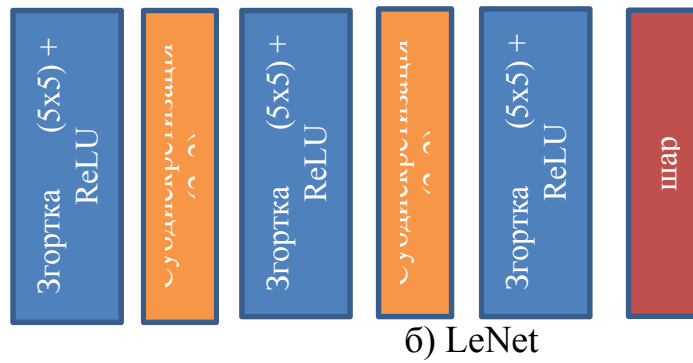
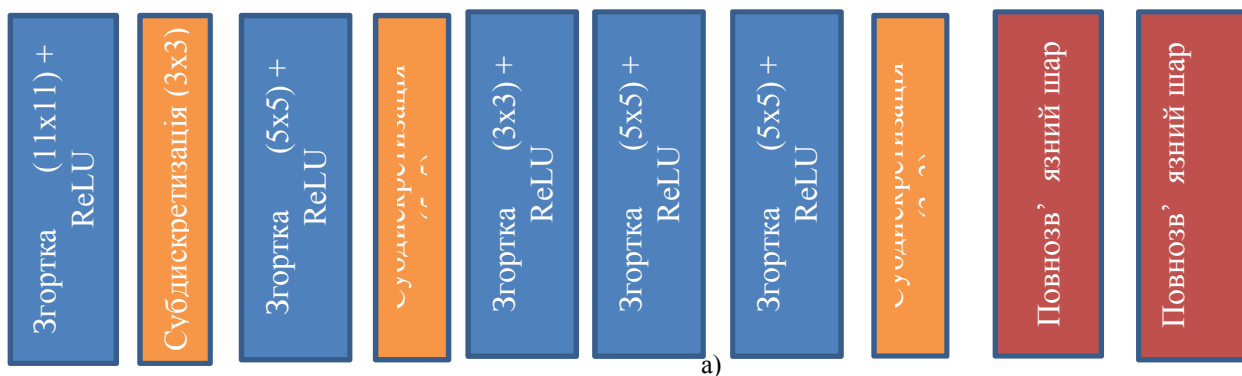


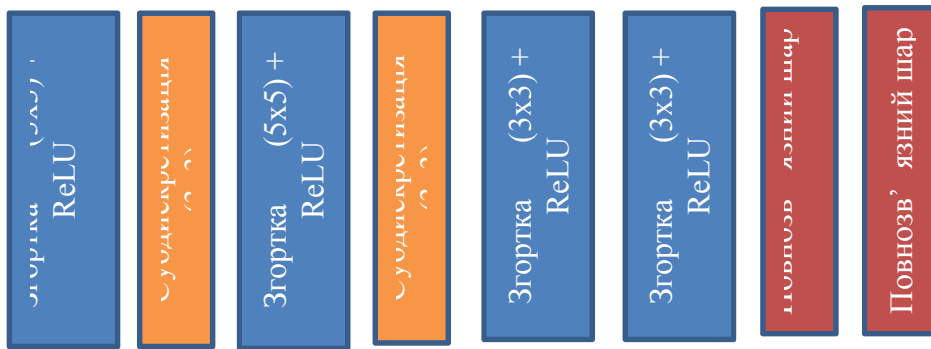
Рисунок 3.7 – Поширені структури ЗНМ

Недоліками цитологічних зображень є низький рівень контрасту та зашумленість, тому у даній роботі запропоновано декілька нових моделей ЗНМ. Навчальну вибірку зображень поділено на такі класи:


- цито – кістозна – мастопатія;
- цито – мастопатія;
- цито – непроліферативна – фібро – мастопатія;
- рак.

Розглянемо наступні моделі ЗНМ для класифікації цитологічних та гістологічних зображень (рисунок 3.8).





б)



в)

Рисунок 3.8 – Запропоновані моделі ЗНМ для класифікації цитологічних та гістологічних зображень

Приклади афінних перетворень наведено у таблиці 3.2.

Таблиця 3.2 - Приклади афінних перетворень

Графічний інтерфейс модулю для здійснення афінних перетворень наведено на рисунку 3.9.

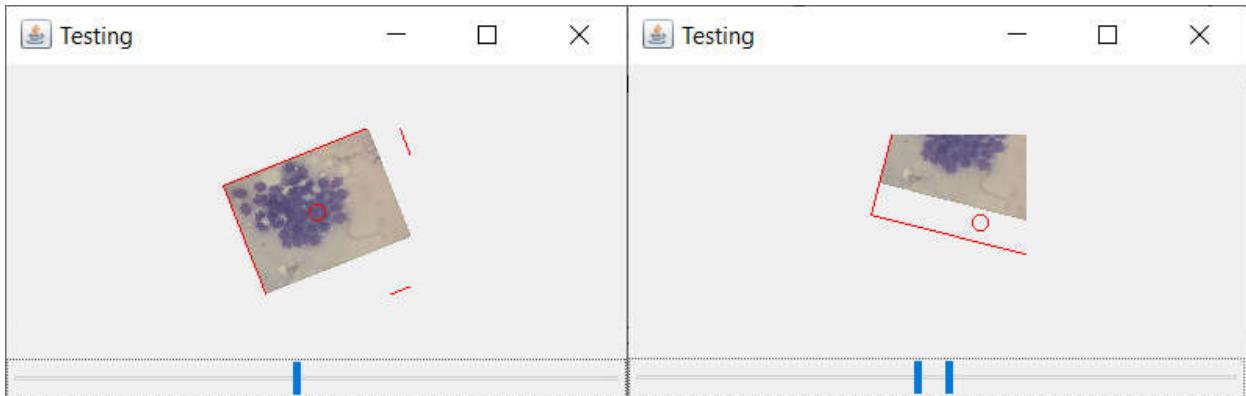


Рисунок 3.9 - Графічний інтерфейс модулю для здійснення афінних перетворень

Лістинг програмного коду для здійснення афінних перетворень:

```
public class RotationPane extends JPanel {
    private BufferedImage img;
    private BufferedImage rotated;
    private double angle;
    private Point clickPoint;

    public RotationPane() {
        try {
            img = ImageIO.read(new File("E:/drive/DL4J_UI/dl4j-
examples/cyto/2/TS_05_08_16_18_47.bmp"));
            BufferedImage scaled = new BufferedImage(img.getWidth() / 2, img.getHeight() /
2, BufferedImage.TYPE_INT_ARGB);
            Graphics2D g2d = scaled.createGraphics();
            g2d.setTransform(AffineTransform.getScaleInstance(0.5d, 0.5d));
            g2d.drawImage(img, 0, 0, this);
            g2d.dispose();
            img = scaled;
            setAngle(0d);
        } catch (IOException ex) {
            ex.printStackTrace();
        }
    }
}
```

```

    }

    addMouseListener(new MouseAdapter() {

        @Override
        public void mouseClicked(MouseEvent e) {
            clickPoint = e.getPoint();
            repaint();
        }

    });

}

public void setAngle(double angle) {
    this.angle = angle;

    double rads = Math.toRadians(getAngle());
    double sin = Math.abs(Math.sin(rads)), cos = Math.abs(Math.cos(rads));
    int w = img.getWidth();
    int h = img.getHeight();
    int newWidth = (int) Math.floor(w * cos + h * sin);
    int newHeight = (int) Math.floor(h * cos + w * sin);

    rotated = new BufferedImage(newWidth, newHeight,
BufferedImage.TYPE_INT_ARGB);
    Graphics2D g2d = rotated.createGraphics();
    AffineTransform at = new AffineTransform();
    at.translate((newWidth - w) / 2, (newHeight - h) / 2);

    int x = clickPoint == null ? w / 2 : clickPoint.x;
    int y = clickPoint == null ? h / 2 : clickPoint.y;

    at.rotate(rads, x, y);
    g2d.setTransform(at);
}

```

```

g2d.drawImage(img, 0, 0, this);
g2d.setColor(Color.RED);
g2d.drawRect(0, 0, newWidth - 1, newHeight - 1);
g2d.dispose();

repaint();
}

```

3.3 Порівняльний аналіз результатів класифікації зображень

Вікно модуля класифікації зображень з використанням ЗНМ наведено на рисунку 3.10.

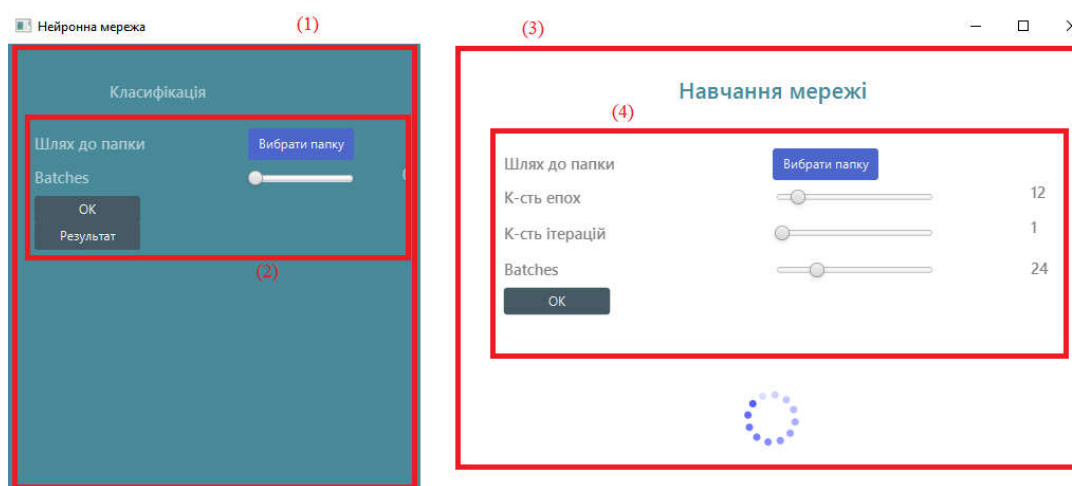


Рисунок 3.10 – Графічний інтерфейс вікна модуля класифікації зображень

(1)– Блок тестування ЗНМ. Користувачу потрібно вибрати директорію із тестовою вибіркою та вказати розмір batches за допомогою повзунка. Після опрацювання користувачу відображаються результат класифікації як показано на рисунку 3.11.

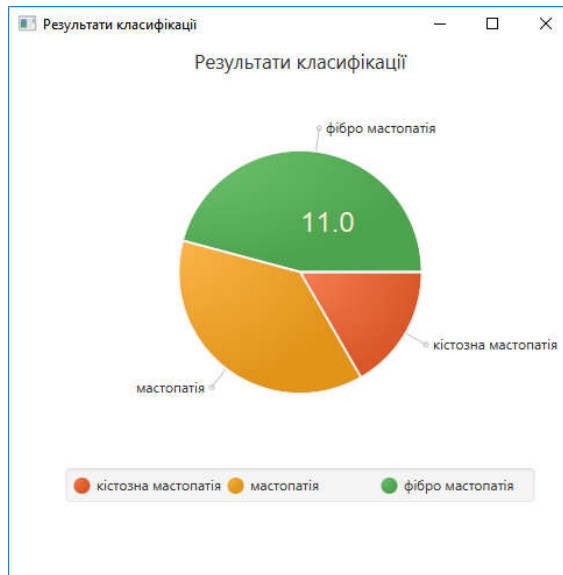


Рисунок 3.11 – Вікно результату класифікації

- (2) - Блок налаштування параметрів ЗНМ.
- (3)– Блок навчання ЗНМ. Користувачу потрібно вибрати директорію з маркованими зображеннями.
- (4) - Блок налаштування параметрів навчання ЗНМ. Окрім вибору директорії із навчальною вибіркою, користувач за допомогою повзунка вказує кількість епох, кількість ітерацій та розмір batches.

Результати класифікації оригінальної вибірки та згенерованої афінними перетвореннями наведено на рисунку 3.12.




Рисунок 3.12 - Результати класифікації оригінальної вибірки та згенерованої афінними перетвореннями

Отже, в результаті аналізу можна зробити висновок, що точність класифікації для зображень, які були спотворені афінними перетвореннями є допустимою у порівнянні із оригінальними зображеннями.

ВИСНОВКИ

В результаті виконання магістерської роботи отримано такі результати:

1. Здійснено аналіз цитологічних зображень раку молочної залози , що дало можливість виділити характерні ознаки цих зображень.
2. Проаналізовано архітектури штучних нейронних мереж для аналізу та синтезу зображень, що дало змогу обґрунтувати напрям дослідження.
3. Проаналізовано структури генеративно-змагальних мереж (глибоко-згорткових генеративно-змагальних мереж) і розглянуто їх застосування для синтезу біомедичних зображень.
4. Розроблено структуру програмного модуля генерування цитологічних зображень , що дало змогу його програмно реалізувати.
5. Розроблена архітектура згорткової нейронної мережі, яка лягла в основу побудови GAT мереж для синтезу зображень.
6. Здійснено порівняльний аналіз класифікації цитологічних зображень, штучно згенерованих та реальних, отриманих дослідним шляхом.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Методичні вказівки до оформлення курсових проектів, звітів про проходження практики, випускних кваліфікаційних робіт для студентів спеціальності «Комп'ютерна інженерія» / І.В. Гураль, Л.О. Дубчак / Під ред. О.М. Березького. - Тернопіль: ТНЕУ, 2019. – 33 с.
2. Методичні рекомендації до виконання магістерської роботи з освітнього ступеня “Магістр”. Спеціальність: 123 - Комп'ютерна інженерія. Магістерська програма - Комп'ютерна інженерія" / О.М. Березький, Л.О. Дубчак, Г.М. Мельник /Під ред. О.М. Березького – Тернопіль: ТНЕУ, 2018.– 41 с.
3. О.М. Березький, П.Б. Лящинський, П.Б. Лящинський, А.Р. Сухович, Т.М. Долинюк. Синтез біомедичних зображень на основі генеративно-змагальних мереж // УЖІТ 2019 №1 – (прийнято до друку).
4. Публікація та апробація ВКР. Синтез біомедичних зображень на основі генеративно-змагальних мереж: зб. тез наук.-практ. конф. / Інтелектуальні комп'ютерні системи та мережі, Тернопольського національного економічного університету. — К.: ФКІТ, 2019. — 55 с.
5. Публікація та апробація ВКР. Синтез цитологічних зображень на основі згорткових нейронних мереж: зб. тез II наук.-практ. конф. Молодих вчених і студентів / Інтелектуальні комп'ютерні системи та мережі, Тернопольського національного економічного університету. — К.: ФКІТ, 2019. — 41 с.
6. Саймон Хайкин, Нейронные сети: полный курс 2-е издание, : Пер. англ. – М. :. Издательский дом “Вильямс”, 2006, 1104 с. : ил. Парал. тит. англ. ISBN 5-8459-0890-6 (рус.).
7. Гонсалес Р., Вудс Р., Цифровая обработка изображений: Издание 3-е, исправленное и дополненное, Пер. - Москва: Техносфера, 2012. – 1104 с. , ISBN 978-5-94836-331-8.

8. Березький О. М. Інтелектуальна система автоматизованої мікроскопії аналізу гістологічних та цитологічних зображень / О.М. Березький, О.Й. Піцун, П.Б. Ляцинський, Г.М. Мельник // Штучний інтелект, Київ, 2017. - №2 (76). - С. 128-140.
9. Березький О.М. Класифікація гістологічних та цитологічних зображень на основі згорткових нейронних мереж / О.М. Березький, О.Й. Піцун, А. Р. Боднар, Т.М. Долинюк // Штучний інтелект - Київ, 2017. - №1 (75). - С. 33-42.
10. Свідоцтво про реєстрацію авторського права на твір №75360. Комп'ютерна програма «Інтелектуальна система діагностування передракових станів молочної залози на основі аналізу гістологічних та цитологічних зображень "HIAMS"». / О.М. Березький, О.Й. Піцун, Г.М. Мельник, П.Б. Ляцинський, П.Б. Ляцинський. Дата реєстрації 14.12.2017 р.
11. Методы и модели анализа данных: OLAP и Data Mining / Барсегян А.А., Куприянов М.С., Степаненко В.В., Холод И.И. - СПб .: БХВ-Петербург, 2004. - 336 с.
12. Методи, алгоритми і програмні засоби опрацювання біомедичних зображень / Березький О. М., Батько Ю.М., Березька К.М., Вербовий С.О., Дацко Т.В., Дубчак Л.О., Ігнатєв І.В., Мельник Г.М., Николіук В.Д., Піцун О.Й. Тернопіль: Економічна думка, ТНЕУ, 2017. 330 с.
13. AdaNet: Adaptive Structural Learning of Artificial Neural Networks Kuznetsov, Vitaly, Mohri, Mehryar, and Syed, Umar. Multi-class deep boosting. In NIPS, 2014.
14. 7. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов, В.В. Борисов. - 2002. - 382 с.
15. Божич В.И. Разработка генетического алгоритма обучения нейронных сетей В.И. Божич О.Б., Лебедев Ю.Л. Шницер // Перспективные информационные технологии и интеллектуальные системы. - 2011. - № 1. - С. 21-24.

16. Нейронных сетей - Использование нейронных сетей. - 2014. Режим доступа: <http://oldconf.neasmo.org.ua> - Использование нейронных сетей.
17. Abarbanel H.D.I. Analysis of Observed Chaotic Data, New York: SpringerVerlag, 1996.
18. Abraham R.H. and C.D. Shaw. Dynamics of the Geometry of Behavior, Reading, MA: Addison-Wesley, 1992.
19. Abu-Mostafa Y.S. "Hints", Neural computation, 1995, vol. 7, p. 639-671.
20. Abu-Mostafa Y.S. "Learning from hints in Neural Networks", Journal of Complexity, 1990, vol. 6, p. 192-198.
21. Abu-Mostafa Y.S. "The Vapnik-Chervonenkis Dimension: Information Versus Complexity in Learning", Neural Computation, 1989, vol. 1, p. 312-317.
22. Abu-Mostafa Y.S. and J.M. St. Jacques. "Information capacity of the Hopfield model", IEEE Transactions on Information Theory, 1985, vol. IT-31, p. 461-464.
23. Snoek, Jasper, Larochelle, Hugo, and Adams, Ryan P. Practical Bayesian Optimization of Machine Learning Algorithms. In Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q. (eds.), NIPS, pp. 2951–2959. Curran Associates, Inc., 2012.
24. Ian J. Goodfellow, Jean Pouget-Abadie*, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair†, Aaron Courville, Yoshua Bengio, "Generative Adversarial Nets," Departement d'informatique et de recherche op ´ erationnelle ´ Universite de Montr ´ eal ´ Montreal, QC H3C 3J7, 2014, p. 9.
25. Islam, Md Monirul, Yao, Xin, and Murase, Kazuyuki. A constructive algorithm for training cooperative neural network ensembles. IEEE Transactions on Neural Networks, 14(4):820–834, 2003.
26. Janzamin, Majid, Sedghi, Hanie, and Anandkumar, Anima. Generalization bounds for neural networks through tensor factorization. arXiv:1506.08473, 2015.
27. Shailza Jolly, Brian Kenji Iwana, Ryohei Kuroki, Seiichi Uchida, "How do Convolutional Neural Networks Learn Design?," In arXiv, 2018.

28. Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” URL <http://code.google.com/p/cuda-convnet/>.
29. Li Xu, Jimmy SJ. Ren, Ce Liu, Jiaya Jia, Deep Convolutional Neural Network for Image Deconvolution, URL : <http://www.lxu.me/projects/dcnncnn/>.
30. Corinna Cortes, Xavier Gonzalvo, Vitaly Kuznetsov, Mehryar Mohri, Scott Yang, “AdaNet: Adaptive Structural Learning of Artificial Neural Networks,” In arXiv 1607.01097v3, 2017.
31. Huang, Gao, Liu, Zhuang, and Weinberger, Kilian Q. Densely connected convolutional networks. CoRR, 2016.
32. Choromanska, Anna, Henaff, Mikael, Mathieu, Michael, Arous, Gerard Ben, and LeCun, Yann. The loss surfaces of multilayer networks. arXiv:1412.0233, 2014.
33. Breuleux, O., Bengio, Y., and Vincent, P. (2011). Quickly generating representative samples from an RBM-derived process. *Neural Computation*, 23(8), 2053–2073.
34. Geert Litjens, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Mohsen Ghahfoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken, Clara I. Sanchez, “A Survey on Deep Learning in Medical Image Analysis,” In arXiv 1702.05747v2, 2017.
35. Rifai, S., Bengio, Y., Dauphin, Y., and Vincent, P. (2012). A generative process for sampling contractive auto-encoders. In ICML’12.
36. Bengio, Y., Thibodeau-Laufer, E., and Yosinski, J. (2014a). Deep generative stochastic networks trainable by backprop. In ICML’14.
37. H. Hotelling, “Analysis of a complex of statistical variables into principal components,” *J. Educ. Psychol.*, vol. 24, no. 6, pp. 417, 1933.
38. M. Gutmann and A. Hyvärinen, “Noise-contrastive estimation: A new estimation principle for unnormalized statistical models,” *Artif. Intell. Statist.*, vol. 1, no. 2, p. 6, 2010.

39. Tim Salimans, Ian Goodfellow, Wojciech Zaremba, Vicki Cheung, Alec Radford, Xi Chen, “Improved Techniques for Training GANs,” In arXiv, 2016.
40. Pauline Luc, Camille Couprie, Soumith Chintala, Jakob Verbeek, “Semantic Segmentation using Adversarial Networks,” In arXiv, 2016.
41. Samer Hijazi, Rishi Kumar, and Chris Rowen, IP Group, Cadence, Using Convolutional Neural Networks for Image Recognition, URL <https://www.cadence.com/>.
42. Xian Wu, Kun Xu, and Peter Hall, A Survey of Image Synthesis and Editing with Generative Adversarial Networks, TSINGHUA SCIENCE AND TECHNOLOGY ISSN11007-02141109/1511pp660-674, 2017.
43. Salome Kazeminaa, Christoph Baurb, Arjan Kuijperc Bramvan Ginnekend, Nassir Navabb, Shadi Albarqouni Anirban Mukhopadhyaya, GANs for Medical Image Analysis, arXiv:1809.06222v2 [cs.CV] 21 Dec 2018.
44. 1st Qianqian Zhang, 2nd Haifeng Wang, 3rd Hongya Lu, 4th Daehan Won, 5th Sang Won Yoon, Medical Image Synthesis with Generative Adversarial Networks for Tissue Recognition, 2575-2634/18/\$31.00 ©2018 IEEE DOI 10.1109/ICHI.2018.00030.
45. Berezsky O. GPU-based biomedical image processing / Berezsky O., Pitsun O., Dubchak L., Liashchynskiy P., Liashchynskiy P. // 14th International Conference on Perspective Technologies and Methods in MEMS Design, MEMSTECH 2018 – Proceedings – 96-99 pp.
46. Синтез біомедичних зображень на основі генеративно-змагальних мереж / О.М. Березький, П.М. Лящинський, П.М. Лящинський, А.Р. Сухович, Т.М. Долинюк. - УЖІТ 2019 № 1, С.123 132.
47. Березький О.М. Засоби класифікації біомедичних зображень на основі нейронних мереж / О.М. Березький, О.Й. Піцун // Науковий вісник НЛТУ України, 2018, т. 28, № 9.
48. He Zhao, Huiqi Li, Sebastian Maurer-Stroh, Li Cheng, Synthesizing Retinal and Neuronal Images with Generative, Adversarial Nets, S1361-8415(18)30459-6 DOI: 10.1016/j.media.2018.07.001.

49. Maayan Frid-Adar, Idit Diamant, Eyal Klang, Michal Amitai, Jacob Goldberger, and Hayit Greenspan, Member, IEEE, GAN-based Synthetic Medical Image Augmentation for increased CNN Performance in Liver Lesion Classification, arXiv:1803.01229v1 [cs.CV] 3 Mar 2018.
50. Geert Litjens, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Mohsen Ghafoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken, Clara I. Sanchez', A Survey on Deep Learning in Medical Image Analysis.
51. John T. Guibas, Tejpal S. Virdi, Peter S. Li, Synthetic Medical Images from Dual Generative Adversarial Networks.
52. Y. Bengio, L. Yao, G. Alain, and P. Vincent, "Generalized denoising autoencoders as generative models," in Proc. Advances Neural Information Processing Systems Conf., 2013, pp. 899–907.
53. L. A. Gatys, A. S. Ecker, and M. Bethge, Texture synthesis using convolutional neural networks, in Proc. 28th Int. Conf. Neural Information Processing Systems, Montreal, Canada, 2015, pp. 262–270.
54. K. Simonyan and A. Zisserman, Very deep convolutional networks for large-scale image recognition, in Int. Conf. Learning Representations (ICLR), San Diego, CA, USA, 2015.
55. Li and M. Wand, Precomputed real-time texture synthesis with Markovian generative adversarial networks, in Proc. 14th European Conf. Computer Vision (ECCV), Amsterdam, The Netherlands, 2016, pp.702–716.
56. L. A. Gatys, A. S. Ecker, and M. Bethge, Image style transfer using convolutional neural networks, in Proc. 2016 IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 2414–2423.
57. A. Radford, L. Metz, and S. Chintala, Unsupervised representation learning with deep convolutional generative adversarial networks, in Int. Conf. Learning Representations (ICLR), San Juan, Puerto Rico, 2016.

58. U. Bergmann, N. Jetchev, and R. Vollgraf, Learning texture manifolds with the periodic spatial GAN, in Proc. 34th Int Conf. Machine Learning, Sydney, Australia, 2017.
59. C. Dong, C. C. Loy, K. M. He, and X. O. Tang, Learning a deep convolutional network for image super-resolution, in Proc 13th European Conf. Computer Vision (ECCV), Zurich, Switzerland, 2014.
60. J. Kim, J. K. Lee, and K. M. Lee, Deeply-recursive convolutional network for image super-resolution, in Proc. 2016 IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 1637–1645.
61. W. Z. Shi, J. Caballero, F. Huszar, J. Totz, A. P. Aitken, R. Bishop, D. Rueckert, and Z. H. Wang, Real-time single image and video super-resolution using an efficient subpixel convolutional neural network, in Proc. 2016 IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 1874–1883.
62. D. Berthelot, T. Schumm, and L. Metz, BEGAN: Boundary equilibrium generative adversarial networks, arXiv preprint arXiv: 1703.10717, 2017.
63. B. Huanget, W. H. Chen, X. M. Wu, and C. L. Lin, High-quality face image SR using conditional generative adversarial networks, arXiv preprint arXiv: 1707.00737, 2017.
64. D. Pathak, P. Krahenbühl, J. Donahue, T. Darrell, and A. A. Efros, Context encoders: Feature learning by inpainting, in Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016.
65. C. Yang, X. Lu, Z. Lin, E. Shechtman, O. Wang, and H. Li, High-resolution image inpainting using multi-scale neural patch synthesis, in Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017.
66. F. Yu and V. Koltun, Multi-scale context aggregation by dilated convolutions, in Int. Conf. Learning Representations (ICLR), San Juan, Puerto Rico, 2016.
67. Object-oriented programming (OOP) - Object-oriented programming (OOP)- 2019. Режим доступа: <https://searchapparchitecture.techtarget.com/> - Object-oriented programming (OOP).

68. JavaScript - What JavaScript can be used for - 2019. Режим доступа:
<https://www.theserverside.com/> - What JavaScript can be used for.
69. Java - Programs created in Java offer - 2019. Режим доступа:
<https://www.theserverside.com/> - Programs created in Java offer.
70. Java variables - What is variable - 2019. Режим доступа:
<https://howtodoinjava.com/> - Java variables.