

КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ІМЕНІ ТАРАСА ШЕВЧЕНКА
ФАКУЛЬТЕТ РАДІОФІЗИКИ, ЕЛЕКТРОНІКИ ТА КОМП'ЮТЕРНИХ СИСТЕМ
Кафедра медичної радіофізики

До захисту допущено:

«На правах рукопису»

Завідувач кафедри _____ Сергій РАДЧЕНКО

« _ » травня 2023 р.

КВАЛІФІКАЦІЙНА МАГІСТЕРСЬКА РОБОТА

на тему:

**«ОЦІНЮВАННЯ АРХІТЕКТУР ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ
ЗНЕШУМЛЕННЯ МАГНІТНО-РЕЗОНАНСНИХ МЕДИЧНИХ ЗОБРАЖЕНЬ»**

Виконав:

студент 2-го курсу магістратури
денної форми навчання
спеціальності 105 Прикладна фізика та наноматеріали
ОНП «Біомедична фізика, інженерія та інформатика»
Слюсаренко Денис Геннадійович

Науковий керівник:

канд. фіз.-мат. н., доцент
Нетреба Андрій В'ячеславович

Рецензент:

д. техн. н., с.н.с.
Яцишин Андрій Васильович

Засвідчую, що у цій магістерській роботі
немає запозичень з праць інших авторів без
відповідних посилань

Студент _____

Робота допущена до захисту в ЕК рішенням кафедри медичної радіофізики
від «__» травня 2023 р., протокол № __.

Завідувач кафедри медичної радіофізики,
канд. фіз.-мат. наук, доцент
Радченко Сергій Петрович

РЕФЕРАТ

Дипломна робота магістра: 47 ст. 19 рис. 8 таблиць. 19 джерел

Запропоновано кілька різних архітектур згорткових нейронних мереж для задачі знешумлення медичних зображень. Зроблено попередню обробку даних DICOM. Повторно кілька разів навчено кожну модель з підбиранням різних гіперпараметрів. Показано як кожна з моделей справляється з різними типами шуму. Перевірено якість знешумлення за допомогою показників SSIM та PSNR. Кращу модель застосовано для знешумлення зображень, представлених у k-області. Показано основні переваги і недоліки обраних мереж та запропоновано подальші ідеї щодо можливостей застосування і покращення отриманих моделей.

**ЗГОРТКОВІ НЕЙРОННИ МЕРЕЖІ, ШТУЧНИЙ ІНТЕЛЕКТ, МРТ, ШУМ,
АВТОЕНКОДЕРИ, ПЕРСЕПТРОН, К-ПРОСТІР.**

Зміст

Вступ	5
1. Архітектури нейронних мереж.....	6
1.1 Автоенкодери	6
1.2 U-net	9
1.3 DnCNN	11
1.4 REDNet.....	13
2. Методи оцінки якості знешумлення.....	15
2.1. Пікове співвідношення сигнал/шум (PSNR)	15
2.2. Індекс структурної подібності (SSIM)	16
3. Використання нейронних мереж для знешумлення МРТ даних.....	20
3.1 Використані набори медичних даних	20
3.2 Види доданого шуму	21
Шум Гаусса.....	21
Пуасонівський шум.....	21
Шум «солі та перцю»/імпульсний шум	22
3.3. Оцінка нейронних мереж.....	24
Застосування U-Net	24
Пікове співвідношення сигнал/шум (PSNR)	25
Індекс структурної подібності (SSIM)	26
Застосування DnCNN	28
Пікове співвідношення сигнал/шум (PSNR)	29
Індекс структурної подібності (SSIM).....	30
Застосування REDNet.....	32
Пікове співвідношення сигнал/шум (PSNR)	33
Індекс структурної подібності (SSIM)	35
3.4. Підсумки.....	36
4. Застосування REDNet для знешумлення медичних зображень з доданим шумом у k-простір.....	39
4.1. Переведення DICOM зображень в k-простір	39

4.2. Оцінка якості знешумлення (PSNR та SSIM).....	40
Висновки	45
Список використаної літератури.....	48

Вступ

В останні роки використання глибоких нейронних мереж для усунення шумів стало популярною темою в області обробки зображень. Здатність цих мереж вивчати складні шаблони та взаємозв'язки в зображеннях призвела до їх успішного застосування в різноманітних задачах усунення шумів на зображеннях. Використовуючи потужні можливості навчання глибоких нейронних мереж, дослідники змогли досягти найсучасніших результатів із усунення шумів на зображеннях.

Головна ідея роботи полягає в тому, що навчаючи різні моделі нейронних мереж видаляти штучно додані шуми ми можемо навчити їх в подальшому знаходити і видаляти подібні шуми вже без додавання штучних шумів. Спочатку моделі навчаються на більш простих видах шуму, але далі можна переходити на більш складні типи шумів, проте тут постає задача правильного підбору архітектури мережі і всіх її параметрів. На магнітно-резонансну томографію (МРТ) можуть впливати різні типи шуму. І, насправді, ці моделі нейронних мереж можуть бути навчені видаляти найпоширеніші види складних шумів, які присутні на зображеннях МРТ(магнітно-резонансної томографії), а саме: тепловий шум, дробовий шум, шум дрейфу та артефакт Гіббсу.

Однією з найпопулярніших архітектур нейронних мереж для усунення шумів на зображеннях є DnCNN (Глибока згорточна нейронна мережа), яка використовує підхід глибокого навчання для усунення шумів у зображеннях шляхом навчання на зображеннях із зашумленістю та їхніх відповідних чистих аналогах. Іншою популярною архітектурою для усунення шумів на зображенні є U-Net, яка є повністю згортковою нейронною мережею, яка поєднує в собі шляхи звуження та розширення для захоплення інформації в різних масштабах. RedNet, з іншого боку, є класом залишкових нейронних мереж, які показали

багатообіцяючі результати у видаленні шумів у задачах шляхом вивчення залишкових функцій.

Загалом, використання методів глибокого навчання для зменшення шуму на МРТ-зображеннях є важливою медичною областю досліджень, яка має потенціал для значного покращення якості та користі візуалізації.

1. Архітектури нейронних мереж

1.1 Автоенкодера

Автоенкодер — це, по суті, нейронна мережа, яка розроблена для вивчення функції неконтрольованої ідентифікації, щоб вона могла стискати та реконструювати вихідний вхідний сигнал і таким чином знаходити більш ефективне та стиснене представлення вихідного введення. Варто зазначити, що ця ідея виникла в 1980-х роках і пізніше була висунута в основоположній статті Хінтона і Салахутдінова в 2006 році.[1]

Автоенкодера широко використовуються для стиснення та реконструкції зображень. Реконструкція зображення в основному означає, що мережа намагається згенерувати будь-яке зображення, яке ми передаємо їй на вхідній фазі.

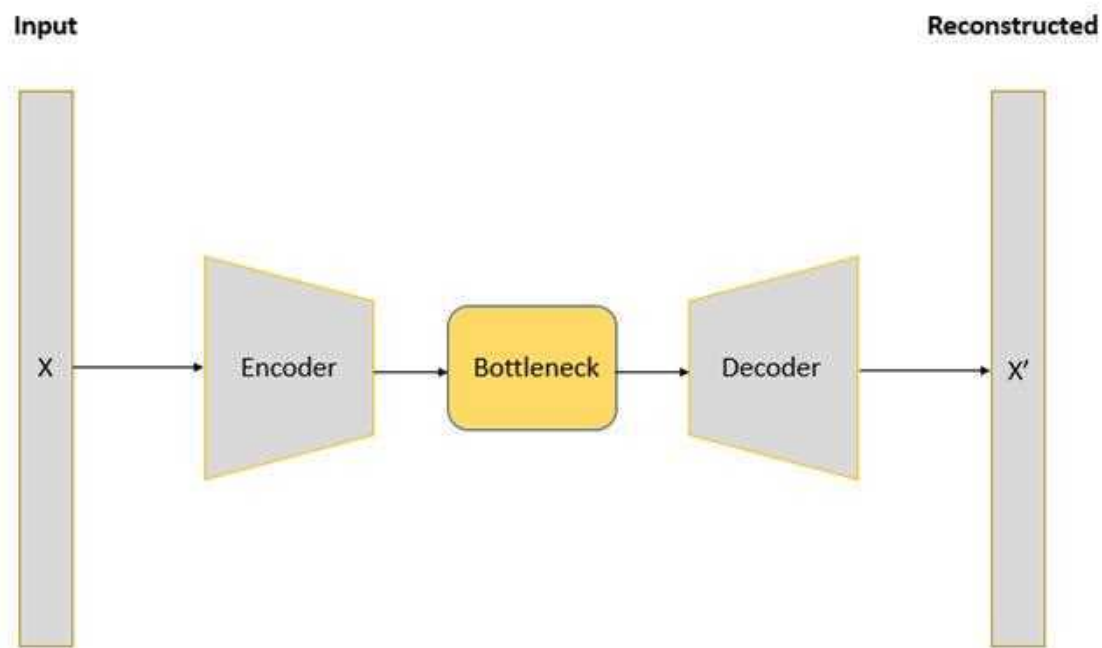


Рис. 1.1. Ілюстрація архітектури автоенкодера.

Автоенкодер складається з 3 основних частин:

1. Кодер: стискає вхідні дані набору train-validate-test у центральне закодоване представлення.
2. Вузьке місце: містить стислі представлення попередніх знань і тому є найважливішою частиною такої мережі.
3. Декодер: допомагає мережі «розпакувати» подання знань із вузького місця та реконструювати ці дані з їхньої закодованої форми.

Наступна формула показує нам втрати в такій нейронній мережі:

$$L(\theta, \varphi) = \frac{1}{n} \sum_{i=1}^n (x^i - f_{\theta}(g_{\varphi}(x^i)))^2$$

Звідси видно, що функція втрати залежить від " θ " і " φ ", які є параметрами, що визначають кодер і декодер. Як було показано раніше на рис. 1, кодер

представлений як $G\phi$, а декодер представлений як $F\theta$, і вони представляють ваги та зміщення нейронної мережі.

Отже, у рівнянні ми підсумовуємо різницю між вихідним зображенням x і реконструйованим зображенням $F\theta(G\phi(x))$. Це математичне представлення також показує нам потік даних від кодера до декодера (тобто введення-виведення).

У зашумлених автокодерах ми пропонуємо зашумлену версію зображення, де шум додано цифровими маніпуляціями. Зображення з шумом подається в архітектуру кодера-декодера, а вихід порівнюється з справжнім зображенням, що лежить в основі.

Автоенкодер усуває шум, вивчаючи представлення вхідного сигналу, де шум можна легко відфільтрувати. Хоча усунення шуму безпосередньо із зображення здається складним, автоенкодер робить це шляхом відображення вхідних даних у форму нижчого розміру (як у нестиснутих автокодерах), де фільтрація шуму стає набагато легшою. По суті, шумопоглинаючі автокодери працюють за допомогою нелінійного зменшення розмірності. Але є проблема з прямими методами застосування автоенкодерів: стиснення зображення до меншого прихованого простору призводить до значної втрати даних, тому вихідні дані декодера злегка або дуже розмиті. Для вирішення цієї та інших проблем доречно використовувати більш складні нейронні мережі, особливо коли стоїть питання якомога вищої якості зображення.

1.2 U-net

U-подібна архітектура складається зі схеми кодер-декодер: кодер зменшує просторові розміри в кожному шарі та збільшує кількість каналів. По суті, декодер збільшує просторові розміри, одночасно зменшуючи кількість каналів. Звідси тензор, який передається в декодер, зазвичай називається вузьким місцем. Наприкінці просторові затемнення відновлюються для створення попіксельного прогнозованого вхідного зображення. Для оновлення параметрів мереж такого типу використовується метод зворотного поширення [2].

U-Net виконує деконволюцію на стороні підвищення дискретизації та долає проблему вузького місця, пов'язану з втратою функцій через з'єднання на стороні кодера архітектури (шлях розширення, симетричний шлях звуження). У той же час частина U-Net з підвищенням дискретизації містить багато функціональних каналів, які дозволяють мережі поширювати контекстну інформацію на більш високому рівні роздільної здатності.

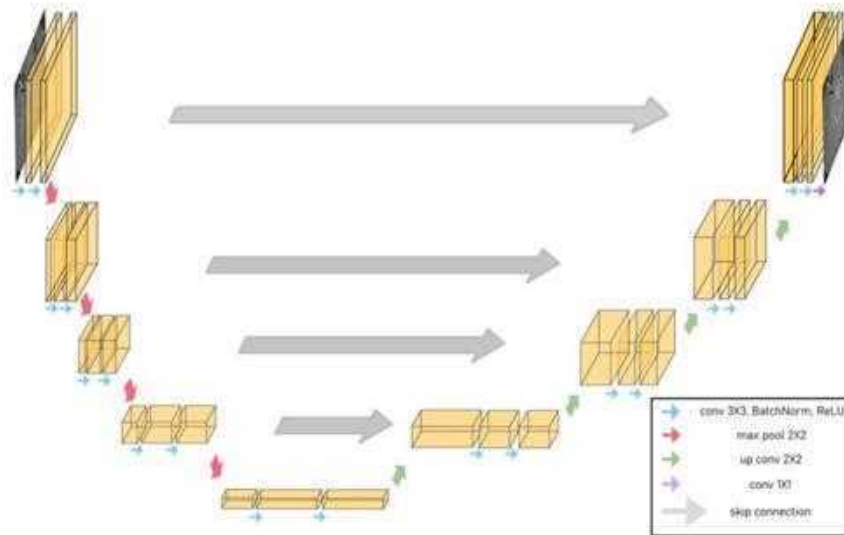


Рис. 1.2. Мережева архітектура U-Net із зашумленням, яка використовується для самоконтролю.

На рисунку 2 наведено загальний вигляд архітектури U-Net. Такий автоенкодер можна еквівалентно розділити на шлях кодування-декодування або шлях скорочення-розширення [3].

Кодер (ліва сторона): складається з повторного застосування двох згорток 3×3 . За кожною конверсією слідує ReLU та нормалізація пакетів. Потім для зменшення просторових розмірів використовується операція злиття 2×2 max. Знову ж таки, на кожному кроці зменшення дискретизації ми подвоюємо кількість каналів функцій, одночасно зменшуючи просторові розміри вдвічі.

Декодер (права сторона): кожен крок у розширеному шляху складається з підвищення дискретизації карти функцій з наступною згорткою транспонування 2×2 , яка вдвічі зменшує кількість каналів функцій. Ми також маємо конкатенацію з відповідною картою об'єктів зі шляху зменшення та зазвичай згортку 3×3 (за кожною слідує ReLU). На останньому рівні згортка 1×1 використовується для відображення каналів у бажану кількість класів. Така архітектура повинна сприяти отриманню якісного декодованого зображення.

У цій роботі реалізована повністю згорточна нейронна мережа. Крім того, вона може бути навчена послідовному навчанню для прогнозування окремих пікселів, він може обробляти вхідні дані довільного розміру [4].

Було створено автокодер, який усуває шум зображення розміром (224, 224, 1). Для кращої роботи на менших зображеннях фігури (224, 224, 1) модель було навчено на більших зображеннях, зображеннях із різними формами, починаючи з (384, 384, 1), завдяки чому реконструкція була більш детальною (менше розмиття).

1.3 DnCNN

DnCNN (Deep Convolutional Neural Network) — базується на повністю згортковій нейронній мережі, яка складається з кількох згорткових шарів і останнього рівня активації. Архітектуру можна розділити на дві частини: перша частина — це мережа вилучення ознак, яка використовує кілька згорткових шарів для вилучення ознак із зашумленого зображення, а друга частина — це мережа відображення, яка відображає витягнуті функції на відповідне чисте зображення.

Архітектура DnCNN зазвичай складається з кількох згорткових рівнів, за якими слідує функція активації випрямленого лінійного блоку (ReLU), яка вносить нелінійність у мережу. Пакедна нормалізація часто використовується для нормалізації виведення кожного рівня та покращення стабільності та конвергенції мережі. Останнім шаром є згортковий шар із лінійною активацією, який виводить знесумлене зображення. [5]

Принцип, що лежить в основі DnCNN, полягає в тому, щоб навчитися зіставляти зображення з шумом і відповідні їм чисті зображення за допомогою великого набору даних пар шумових і чистих зображень. Під час навчання мережа вчиться мінімізувати різницю між передбачуваним чистим зображенням і фактичним чистим зображенням. Це досягається шляхом мінімізації функції втрат, як правило, середньої квадратичної помилки (MSE) між прогнозованими та наземними правдивими зображеннями. Параметри мережі оновлюються за допомогою зворотного поширення, щоб мінімізувати функцію втрат.




Рис. 1.3. Архітектура мережі DnCNN.

Розмір згорткових фільтрів встановлюється рівним 3×3 , і всі шари об'єднання видаляються. Отже, рецептивне поле DnCNN глибиною d має бути $(2d + 1)(2d + 1)$.

Для гаусового усунення шуму з певним рівнем шуму розмір сприйнятливого поля DnCNN встановлено на 35×35 відповідно глибиною 17. Для інших загальних завдань усунення шуму зображення збільшується більше сприйнятливого поля, встановивши глибину рівнем 20. Формулювання залишкового навчання використання для навчання залишкового відображення:

$x = yR(y)$. Таким чином, $R(y)$ вивчається.

Точніше кажучи, існує 3 типи шарів:

1. Conv+ReLU : для першого шару 64 фільтри розміром $3 \times 3 \times c$ використовують для створення 64 карток функцій. $c = 1$ для сірого зображення та $c = 3$ для кольорового зображення.

2. Conv+BN+ReLU : для шарів від 2 до $(D-1)$ використовується 64 фільтри розміром $3 \times 3 \times 64$, а між згорткою та ReLU додається пакетна нормалізація.

3. Conv: для останнього шару c фільтрами розміром $3 \times 3 \times 64$ використовується для реконструкції виходу.

1.4 REDNet

REDNet (Residual Encoder-Decoder Network) — це тип архітектури нейронної мережі, розроблений для завдань відновлення зображень, таких як усунення шумів зображення чи надвисока роздільна здатність.

Архітектура REDNet складається з мережі кодувальника, яка витягує функції високого рівня з вхідного зображення, і мережі декодера, яка використовує ці функції для реконструкції вихідного зображення. Ключовим нововведенням REDNet є використання залишкових з'єднань, які дозволяють мережі вивчати різницю між вхідними та вихідними зображеннями замість вивчення всього відображення. Такий підхід зменшує ризик перенавчання та підвищує точність мережі.




Рис. 1.4. Архітектура мережі REDNet.

Мережа містить рівні симетричної згортки (кодер) і деконволюції (декодер).

Згортка: Згорткові шари діють як екстрактор функцій, який фіксує абстракцію вмісту зображення, одночасно усуваючи шуми/пошкодження.

Деконволюція: Потім деконволюційні шари об'єднуються для відновлення зображення вмісту деталей. Деконволюційні рівні пов'язують одну активацію

входу з кількома виходами. Деконволюція традиційно використовує як навчальний рівень підвищення дискретизації .

З'єднання пропуску/швидкого доступу з'єднуються через кожні кілька (у нашому випадку два) шари від карт згорткових об'єктів до їхніх дзеркальних карт об'єктів дезгортки. Таким чином, відповідь від згорткового шару безпосередньо поширюється на відповідний дзеркальний деконволюційний шар як вперед, так і назад. Передані згорткові карти ознак підсумовуються до деконволюційних карт ознак поелементно та передаються на наступний рівень після виправлення.

2. Методи оцінки якості знешумлення

Оцінка якості зображення (IQA) розглядається як характерна властивість зображення. Деградація сприйманих зображень вимірюється оцінкою якості зображення. Зазвичай погіршення обчислюється порівняно з ідеальним зображенням, відомим як еталонне зображення.

Якість зображення можна описати як технічно, так і об'єктивно, щоб вказати на відхилення від ідеальної або еталонної моделі. Це також стосується суб'єктивного сприйняття або передбачення зображення [6], такого як зображення погляду людини.

Існує дуже багато методів якості зображення, які в основному використовуються для оцінки та оцінки якості зображень, таких як MSE (середня квадратична помилка), UIQI (універсальний індекс якості зображення), PSNR (пікове співвідношення сигнал/шум), SSIM (метод структурованого індексу подібності), HVS (Human Vision System), FSIM (Feature Similarity Index Method) тощо. В даній роботі ми використовували SSIM та PSNR, оскільки для даної задачі вони дадуть найбільш якісну оцінку.

2.1. Пікове співвідношення сигнал/шум (PSNR)

PSNR використовується для обчислення співвідношення між максимально можливою потужністю сигналу та потужністю спотворюючого шуму, який впливає на якість його представлення [8]. Це співвідношення між двома зображеннями обчислюється в децибелах. PSNR зазвичай обчислюється як логарифм масштабу децибел, оскільки сигнали мають дуже широкий динамічний діапазон. Цей динамічний діапазон змінюється між найбільшим і найменшим можливими значеннями, які змінюються за своєю якістю. Пікове відношення сигнал/шум є найбільш часто використовуваним методом оцінки якості для вимірювання якості реконструкції кодеків стиснення зображення з втратами. Сигнал розглядається як вихідні дані, а шум – це помилка, спричинена

стисненням або спотворенням. PSNR — це приблизна оцінка якості реконструкції, яку сприймає людина, порівняно з кодеками стиснення.

PSNR виражається як:

$$\text{PSNR} = 10 \log_{10} (\text{peakval}^2) / \text{MSE}$$

Тут peakval (пікове значення) є максимальним у даних зображення.

MSE – це дисперсія оцінювача у випадку незміщеного оцінювача. Він має ті самі одиниці вимірювання, що й квадрат величини, яка обчислюється як дисперсія.

MSE між двома зображеннями, наприклад $g(x, y)$ і $\hat{g}(x, y)$ визначається як [7]:

$$\text{MSE} = \frac{1}{MN} \sum_{n=0}^M \sum_{m=1}^N [\hat{g}(n, m) - g(n, m)]^2$$

2.2. Індекс структурної подібності (SSIM)

Індекс структурної схожості (SSIM) виділяє із зображення 3 ключові характеристики :

- Яскравість
- Контраст
- Структура

Порівняння між двома зображеннями виконується на основі цих 3 ознак.

На рисунку 5, наведеному нижче, показано розташування та потік системи вимірювання структурної подібності [9]. Сигнал X і сигнал Y стосуються еталонних і зразкових зображень.

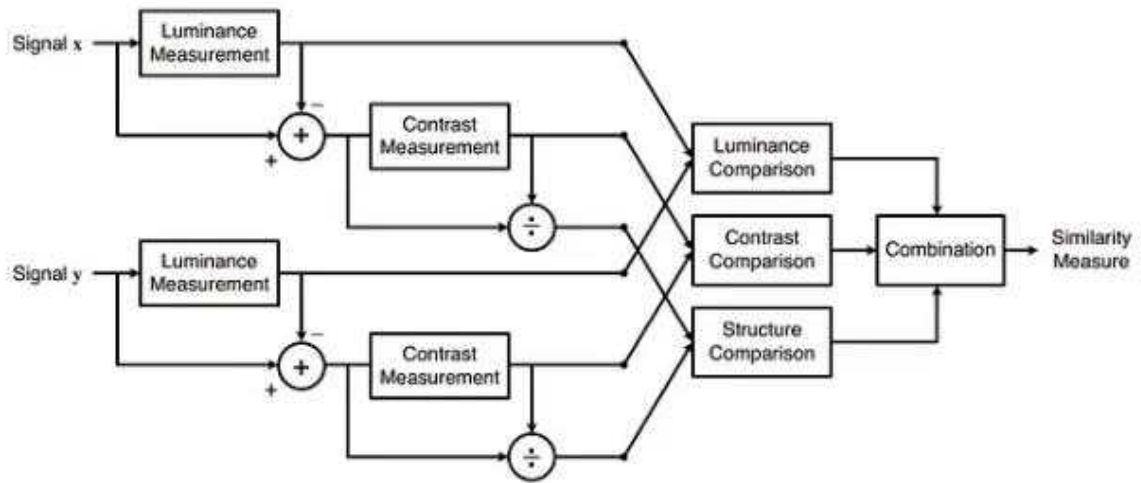


Рис. 2.1. Система вимірювання структурної подібності.

Ця система розраховує структурний індекс подібності між 2 даними зображеннями, який є значенням від -1 до +1. Значення +1 вказує на те, що 2 дані зображення дуже схожі або однакові, а значення -1 вказує на те, що 2 дані зображення дуже різні. Часто ці значення встановлюються в діапазоні [0, 1], де крайні значення мають однакове значення.

Математично оцінка SSIM визначається наступним чином:

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y).$$

де $\alpha > 0$, $\beta > 0$, $\gamma > 0$ позначають відносну важливість кожного з показників. Щоб спростити вираз, якщо припустити, що $\alpha = \beta = \gamma = 1$ і $C3 = C2/2$, ми можемо отримати:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}.$$

Тут враховано всі три характеристики, які окремо можна записати так:
 Яскравість: Яскравість вимірюється шляхом усереднення всіх значень пікселів.
 Його позначають μ і представляється як:

$$\mu_x = \frac{1}{N} \sum_{i=1}^N x_i$$

Контраст : вимірюється стандартним відхиленням (квадратний корінь із дисперсії) усіх значень пікселів. Він позначається σ (сигма) і представлений формулою:

$$\sigma_x = \left(\frac{1}{N-1} \sum_{i=1}^N (x_i - \mu_x)^2 \right)^{\frac{1}{2}}$$

Структура: структурне порівняння виконується за допомогою консолідованої формули (докладніше про це пізніше), але, по суті, ми ділимо вхідний сигнал на його стандартне відхилення, щоб результат мав одиничне стандартне відхилення, що дозволяє більш надійне порівняння:

$$(x - \mu_x) / \sigma_x$$

Також слід не забувати про функцію порівняння контрасту: вона визначається функцією $c(x, y)$, яка показана нижче. σ позначає стандартне відхилення даного зображення. x і y – два зображення, які порівнюються. Записуються наступним чином:

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}$$

Та функцію порівняння контрасту: вона визначається функцією $s(x, y)$, яка показана нижче. σ позначає стандартне відхилення даного зображення. x і y – два зображення, які порівнюються. Записується наступним чином:

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x \sigma_y + C_3}.$$

де $\sigma(xy)$ визначається як:

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y).$$

Для оцінки якості зображення корисно застосовувати індекс SSIM локально, а не глобально [10]. По-перше, статистичні характеристики зображень зазвичай дуже просторово нестационарні. По-друге, спотворення зображення, які можуть залежати або не залежати від локальної статистики зображення, також можуть бути просторовими варіантами. По-третє, на типових відстанях перегляду тільки локальна область зображення може бути сприйнята з високою роздільною здатністю людиною-спостерігачем в один момент часу. І, нарешті, локалізоване вимірювання якості може забезпечити просторово змінну карту якості зображення, яка надає більше інформації про погіршення якості зображення та може бути корисною в деяких програмах. Отже, оскільки тепер ми обчислюємо показники локально, наші формули переглянуто так:

$$\begin{aligned} \mu_x &= \sum_{i=1}^N w_i x_i \\ \sigma_x &= \left(\sum_{i=1}^N w_i (x_i - \mu_x)^2 \right)^{\frac{1}{2}} \\ \sigma_{xy} &= \sum_{i=1}^N w_i (x_i - \mu_x)(y_i - \mu_y). \end{aligned}$$

3. Використання нейронних мереж для знешумлення МРТ даних

3.1 Використані набори медичних даних

У цьому завданні ми використовували дані з Cancer Imaging Archive [11]. Усі набори зображень у форматі DICOM і містять T1w (підготовка до та після контрастування), FLAIR, T2w, ADC, нормалізований мозковий кровотік, нормалізований відносний об'єм церебральної крові, стандартизований відносний об'єм мозкової крові та бінарні маски пухлини (генеровані за допомогою T1w). зображення). Також використовувався окремий набір МР-зображень модальності LAIR. Ці зображення були отримані з Cancer Imaging Archive (TCIA). Цей набір даних містить МРТ-зображення мозку разом із масками сегментації вручну аномалії FLAIR.




Рис. 3.1. Приклади використаних МРТ зображень. a,b,c,d – без раку, без раку, гліома, менингіома.

3.2 Види доданого шуму

Шум Гаусса

Гаусівський шум має рівняння щільності ймовірності нормального розподілу [12]. Гаусівський шум або шум підсилювача додається до МР-зображення під час отримання зображення, наприклад, шум датчика.

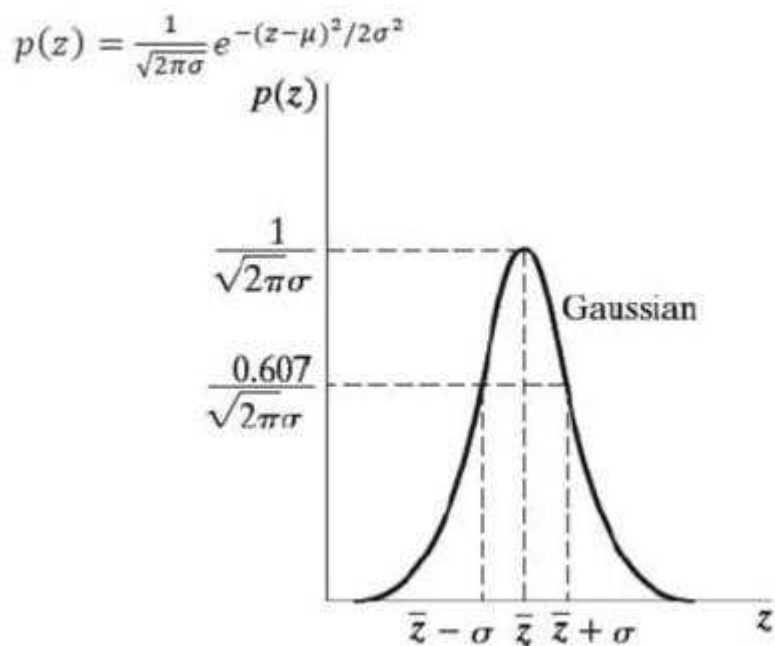


Рис. 3.2. Шум Гаусса

де $P(x)$ – шум рівняння розподілу Гауса на МР-зображенні; μ і σ є середнім і стандартним відхиленням відповідно.

Пуассонівський шум

У МРТ шум Пуассона виникає через випадковий характер основного сигналу, який генерується релаксацією атомів водню в тілі під впливом магнітного поля. Сигнал від кожного вокселя на МРТ-зображенні зазвичай є випадковою величиною з розподілом Пуассона, із середнім значенням розподілу, пропорційним кількості атомів водню у вокселі.

Математично шум Пуассона в зображеннях МРТ можна змоделювати як процес точки Пуассона, де інтенсивність сигналу на кожному вокселі/пікселі є випадковою величиною з розподілом Пуассона [13]. Розподіл Пуассона характеризується одним параметром, λ , який представляє очікуване значення та дисперсію розподілу. У МРТ параметр λ пов'язаний з кількістю атомів водню у вокселі.

Рентгенівські зображення формуються відповідно до статистики підрахунку фотонів, яка слідує за Пуассонівським розподілом, і ці зображення спотворені дробовим шумом, який також відповідає розподілу Пуассона, визначеному рівнянням:

$$P(k) = \frac{\exp(-\lambda)\lambda^k}{k!}$$

Тут λ – середнє, а k – очікуване значення.

Шум «солі та перцю»/імпульсний шум

Імпульсний шум також визначається шумом «солі та перцю» [14]. Це спричинено несправними пікселями в датчиках камери, несправними ділянками пам'яті в апаратному забезпеченні або передачею в шумному каналі. Він завжди незалежний і не корельований з пікселями МР-зображення. Його два типи - шум солі та перцю та випадковий шум. У типі шуму «Сіль і перець» пікселі з шумом приймають або значення солі (рівень сірого – 225), або значення перцю (рівень сірого – 0), і це виглядає як чорні та білі плями на МР-зображеннях. У разі випадкового імпульсного шуму, шум може мати будь-яке значення рівня сірого від 0 до 225. У цьому випадку шум також випадково розподіляється по всьому МР-зображенню, і ймовірність появи будь-якого значення рівня сірого як шуму буде однаковою.




Рис. 3.3. Імпульсний шум.

Математично цей шум можна записати так:

$$P(z) = \begin{cases} p_a & \text{for } z = a \\ p_b & \text{for } z = b \\ 0 & \text{otherwise} \end{cases}$$

де p_a, p_b – рівняння щільності ймовірностей, $p(z)$ – розподіл шуму солі та перцю на МР-зображенні, a, b – розмір МР-зображення.

На відміну від гаусового чи пуассонівського шуму, який зазвичай випадково й рівномірно розподіляється по всьому зображенню, імпульсний шум виглядає як ізольовані висококонтрастні пікселі або невеликі кластери пікселів. Ці пікселі можуть бути набагато яскравішими або темнішими за навколишні тканини, і вони можуть значно вплинути на діагностичну цінність зображення. Загалом, імпульсний шум може бути значною проблемою для зображень МРТ.

3.3. Оцінка нейронних мереж

Застосування U-Net

Першою архітектурою нейронної мережі, яка була застосована для поставленої задачі, стала U-Net.

Загальний огляд такої нейронної мережі наведено в пункті 1.2. Далі представлено архітектуру мережі:

Вхідний шар:

- 4 блоки понижуючої дискретизації, кожен з яких складається з 2 згорткових шарів з 64 фільтрами кожен, розміром ядра 3x3, кроком 1 і заповненням 1, після чого йде максимальний шар об'єднання з кроком 2.
- Блок вузького місця, що складається з 2 згорткових шарів з 512 фільтрами кожен, розміром ядра 3x3 і заповненням 1.
- 4 блоки підвищення дискретизації, кожен з яких складається з транспонованого згорткового шару з кроком 2, за яким слідує 2 згорткові шари з 64 фільтрами кожен, розміром ядра 3x3 і заповненням 1.

Вихідний шар:

- Функція втрат: середня квадратична помилка (MSE) між знешумленим виходом і істинним зображенням.

В якості алгоритму навчання було використано оптимізатор Адама зі швидкістю навчання 0,001 і розпадом ваги 0,001. Розмір батча – 4.

Нейронна мережа навчається за допомогою набору зображень DICOM із додаванням шуму. Під час навчання мережа вчиться передбачати чисте зображення за шумового входу. Мережа навчається за допомогою зворотного поширення, де градієнти функції втрат щодо параметрів мережі обчислюються та використовуються для оновлення параметрів.

Щоб навчити мережу, ми спочатку розділяємо набір даних на набори для навчання, перевірки та тестування. Потім мережа навчається на навчальному наборі з використанням гіперпараметрів і алгоритму, описаних вище. Ми відстежуємо продуктивність мережі на перевірочному наборі під час навчання та використовуємо ранню зупинку, щоб запобігти перенавчанню.

Після завершення навчання ми оцінюємо продуктивність мережі на тестовому наборі, використовуючи такі показники, як PSNR і SSIM.

Пікове співвідношення сигнал/шум (PSNR)

PSNR є широко використовуваним показником для оцінки якості знімків із шумом. Вищий PSNR вказує на те, що знешумлене зображення більш схоже на вихідне безшумне зображення, тоді як нижчий PSNR вказує на те, що процес знешумлення спричинив більше спотворень у зображенні.

В цілому, якщо показник перевищує значення в 30 Дб, то ми маємо вже хороші результати.

Як можна побачити на рисунку 9, результати свідчать про те, що модель нейронної мережі добре працює для знешумлення медичних зображень, на що вказують високі пікові значення співвідношення сигнал/шум (PSNR). Модель нейронної мережі U-Net має високі значення PSNR для всіх трьох типів шуму: шуму Гауса, шуму Пуассона та шуму перцю та солі. Значення PSNR є найвищими для найнижчих рівнів шуму (1-3%) і поступово зменшуються зі збільшенням рівня шуму.

Окремо слід зазначити, що для третього виду шуму (імпульсного), маємо падіння нижче 30Дб вже на 4% шуму, з чого можна зробити висновок, що обранан архітектура досить погано справляється з подібним видом шуму і для виправлення цього можна спробувати пере налаштувати параметри мережі, або ж використати модель щільної або залишкової U-Net.




Рис. 3.4. Графік PSNR оцінки знешумлення зображень з використанням U-Net

PSNR (dB) U-Net							
% of noise	1	2	3	4	5	6	7
Gaussian noise	35.13	34.26	33.19	31.88	30.94	30.02	29.22
Poisson noise	34.19	33.56	32.37	30.94	30.02	29.23	28.66
Impulse noise	32.59	31.88	30.94	30.16	28.54	27.66	26.94

Табл. 3.1. Значення величини PSNR знешумлення зображень з використанням U-Net

Індекс структурної подібності (SSIM)

SSIM (Індекс структурної схожості) є широко використовуваним показником для оцінки якості зображення. Він вимірює подібність між еталонним зображенням і спотвореним зображенням після того, як нейронна мережа прибравла шум. Значення SSIM варіюються від 0 до 1, де 1 означає ідеальну схожість зображення.

В загальному видно також, що усунення шуму за допомогою нейронної мережі дало хороші результати, зі значеннями SSIM вище 0,85 для всіх трьох типів шуму для 4% шуму.

Головне, маємо для 3% кожного шуму Гаусового шуму значення SSIM близько 90%. Ці результати свідчать про те, що зменшення шуму на медичних зображеннях за допомогою нейронної мережі U-Net може ефективно зменшити вплив шуму та покращити якість зображення, як вимірює метрика SSIM.

Але так само, як у випадку оцінки з допомогою PSNR, так і в даному випадку маємо на 5% шуму падіння до 85% і далі нижче, що також не можна вважати надто хорошим результатом.




Рис. 3.5. Графік SSIM оцінки знешумлення зображень з використанням U-Net

SSIM U-Net							
% of noise	1	2	3	4	5	6	7
Gaussian noise	92.64	91.47	90.35	88.92	88.16	87.31	85.94
Poisson noise	91.33	90.52	89.23	88.01	87.26	86.37	84.22
Impulse noise	89.67	88.74	87.33	86.58	85.33	84.21	83.16

Табл. 3.2. Значення величини SSIM знешумлення зображень з використанням U-Net

Застосування DnCNN

Хоч і U-Net має здатність охоплювати більше просторових деталей [15], вона має свої недоліки, які може виправити застосування архітектури DnCNN. Далі наведено основні відмінності DnCNN від U-Net [16]:

1. DnCNN має простішу архітектуру порівняно з U-Net. Він складається лише з згорткових шарів, без шарів об'єднання чи з'єднань пропуску. Ця простота робить DnCNN більш ефективним з точки зору вимог до обчислень і пам'яті.

2. Завдяки простішій архітектурі DnCNN навчається швидше порівняно з U-Net. Це робить його гарним вибором для великомасштабних завдань з усунення шумів, які вимагають швидкого виконання.

3. Завдяки своїй простішій архітектурі DnCNN менш схильний до переобладнання порівняно з U-Net. Це полегшує навчання на менших наборах даних або наборах даних з обмеженою мінливістю.

Також важливо зазначити, що раніше вже було показано, що DnCNN дуже ефективний у видаленні шуму із зображень, зокрема шуму Гауса [17]. Це завдяки його здатності вивчати статистичні властивості шуму та пригнічувати його, зберігаючи основний зміст зображення.

Загальний опис такої нейронної мережі описаний в пункті 1.3. Нижче наведемо технічний опис:

Архітектура:

Вхідний шар

- 20 згорткових шарів з 64 фільтрами кожен, розміром ядра 3x3, кроком 1 і заповненням 1
- Шар пакетної нормалізації після кожного згорткового шару

- Функція активації ReLU після кожного шару нормалізації партії

Вихідний шар

- Функція втрат: середня квадратична помилка (MSE) між знешумленим виходом і істинним зображенням.

В якості алгоритму навчання використано стохастичний градієнтний спуск (SGD) з імпульсом 0,9 і розпадом ваги 0,0001.

Швидкість навчання починається з 0,001 і зменшується в 10 разів після 10 epoch і 20 epoch. Розмір батча 16.

Всі подальші кроки виконуються так само як для U-Net.

Пікове співвідношення сигнал/шум (PSNR)

При оцінці роботи наступної нейронної мережі, а саме DnCNN ми використали ті самі критерії, як і в попередньому випадку, а, отже, чим вище показник PSNR в Дб, тим більша подрібність оригінального і знешумленого зображень. І, відповідно, хорошим показником можна вважати вже значення 30Дб та вище.

На рисунку 11 представлено співвідношення сигнал/шум(PSNR) при роботі нейронної мережі DnCNN. З нього видно, що для цієї нейронної мережі ми вже маємо кращі результати і для більш складного шуму, такого як шум «солі та перцю». Навіть на 7% шуму ми маємо значення вище за 30Дб, а для шуму в 3% і менше значення сигнал/шум дає високі значення, тобто відновлене зображення маємо дуже подібним до оригінального.

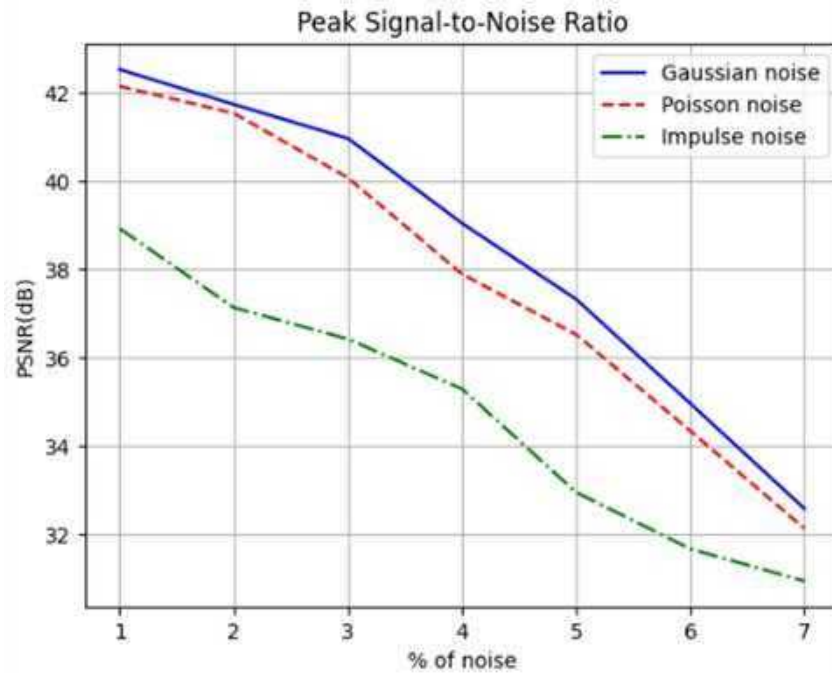


Рис. 3.6. Графік PSNR оцінки знешумлення зображень з використанням DnCNN

PSNR (dB) DnCNN							
% of noise	1	2	3	4	5	6	7
Gaussian noise	95.09	94.12	93.22	92.36	91.11	90.14	89.23
Poisson noise	93.62	92.78	91.64	90.52	89.37	88.62	87.46
Impulse noise	91.03	90.22	89.16	88.22	87.34	86.22	84.51

Табл. 3.3. Значення величини PSNR знешумлення зображень з використанням DnCNN

Індекс структурної подібності (SSIM)

Ми маємо хороші результати знешумлення при використанні обраної нейронної мережі, і, справді, як можна побачити по індексу структурної подібності, для всіх трьох видів шуму, при 7% ми маємо близько 85% подібності або ж вище. На рисунку 12 показано наглядно результати перевірки.

Як висновок, можна зазначити, що дана нейронна мережа здатна працювати з складними видами шуму, а, отже, може бути застосована і для вже наявних шумів в медичних зображеннях. Єдиним важливим моментом є те, що

для більшої якості треба використовувати більші набори даних і, ймовірно, більш індивідуально підібрати гіперпараметри.




Рис. 3.7. Графік SSIM оцінки знешумлення зображень з використанням DnCNN

SSIM DnCNN							
% of noise	1	2	3	4	5	6	7
Gaussian noise	95.09	94.12	93.22	92.36	91.11	90.14	89.23
Poisson noise	93.62	92.78	91.64	90.52	89.37	88.62	87.46
Impulse noise	91.03	90.22	89.16	88.22	87.34	86.22	84.51

Табл. 3.4. Значення величини SSIM знешумлення зображень з використанням DnCNN

Застосування REDNet

Загальний огляд даної архітектури представлено в розділі 1.4. Загалом, архітектура REDNet наймолодша з усіх трьох обраних архітектур, але вона створювалась з ціллю усунення шумів і насправді в теорії має наступні переваги порівняно з попередніми [18]:

1. Може обробляти більші зображення. Оскільки REDNet використовує рекурсивну архітектуру, яка дозволяє обробляти зображення в ієрархічній манері, зменшуючи вимоги до пам'яті для алгоритму.
2. Ще одна перевага REDNet полягає в тому, що він може обробляти різні рівні шуму у вхідних зображеннях. Це тому, що REDNet використовує багатомасштабну архітектуру, яка дозволяє адаптуватися до різних рівнів шуму у вхідних зображеннях.
3. Порівняно з U-Net і DnCNN, REDNet загалом швидше усуває шуми на зображеннях. Це пояснюється тим, що REDNet використовує рекурсивну архітектуру, яка дозволяє ефективніше обробляти зображення.
4. Нарешті, REDNet можна навчити з меншою кількістю даних, ніж U-Net і DnCNN. Це пояснюється тим, що REDNet використовує рекурсивну архітектуру, яка дозволяє ефективніше навчатися на менших наборах даних.

Перейдем до архітектури:

Вхідний шар: 16 залишкових блоків, кожен з яких складається з 2 згорткових шарів з 64 фільтрами кожен, розміром ядра 3x3, кроком 1 і заповненням 1

Вихідний шар: Функція втрат: середня квадратична помилка (MSE) між знешумленим виходом і істинним зображенням.

Алгоритм навчання: оптимізатор Адама зі швидкістю навчання 0,0001 і розпадом ваги 0,0001. Розмір батча 16.

Подальші кроки як і в попередніх випадках.

Пікове співвідношення сигнал/шум (PSNR)

Як вже було зазначено раніше, REDNet — це відносно нова архітектура глибокої нейронної мережі, яка була спеціально розроблена для усунення шумів і високої роздільної здатності медичних зображень.

Використання REDNet для зменшення шуму на медичних зображеннях може забезпечити додаткові покращення якості зображення. Архітектура здатна вивчати складні зв'язки між зашумленими та чистими зображеннями, дозволяючи створювати високоякісні знешумлені зображення навіть за наявності високого рівня шуму. Тому більше уваги було зосереджено саме на ній.

Попередні результати для зменшення шуму на медичних зображеннях за допомогою REDNet, які ми отримали, виявились більш перспективні ніж для попередніх нейронних мереж, тому в подальшому на REDNet зосереджено більше уваги. Тож, поєднання високих значень PSNR і SSIM свідчить про те, що REDNet є ефективним інструментом для зменшення шуму медичних зображень і може давати високоякісні результати навіть за наявності різних типів шуму. На рисунку 13 можна побачити відповідні результати оцінки знешумлення з допомогою співвідношення сигнал/шум. Можна помітити, що результати дещо подібні до роботи DnCNN, і це не дивно оскільки нейронні мережі мають певну подібність, проте, як вже зазначалось раніше, Ключовим нововведенням REDNet є використання залишкових з'єднань, які дозволяють мережі вивчати різницю між вхідними та вихідними зображеннями замість вивчення всього

відображення. І як результат, PSNR для цієї моделі справді трохи вищий за попередню.




Рис. 3.8 Графік PSNR оцінки знешумлення зображень з використанням REDNet

PSNR (dB) REDNet							
% of noise	1	2	3	4	5	6	7
Gaussian noise	43.26	42.51	41.22	39.16	37.54	35.19	33.17
Poisson noise	43.01	42.19	40.66	38.29	36.22	34.92	33.22
Impulse noise	39.64	38.10	36.98	35.77	33.26	32.19	31.66

Табл. 3.5. Значення величини PSNR знешумлення зображень з використанням REDNet

Індекс структурної подібності (SSIM)

Додатково до попередніх висновків, можна додати результати оцінки структурної подібності зображень, і відзначити, щодля всіх трьох видів шуму, при 7% ми маємо близько 85% подібності або ж вище як і у випадку використання DnCNN, проте все ж ці показники трохи вищі. Так, наприклад при роботі з Пуассонівським шумом, на 7% шуму ми маємо SSIM рівне 87,46% у випадку DnCNN та 89,03 у випадку REDNet. На Рисунку 14 представлено більш детально результати SSIM оцінки нейронної мережі REDNet.




Рис. 3.9. Графік SSIM оцінки знешумлення зображень з використанням REDNet

SSIM REDNet							
% of noise	1	2	3	4	5	6	7
Gaussian noise	95.42	94.37	93.55	92.62	91.48	90.54	89.61
Poisson noise	94.93	94.02	93.21	91.99	90.81	89.97	89.03
Impulse noise	92.53	91.71	90.84	89.75	88.35	87.23	85.20

Табл. 3.6. Значення величини SSIM знешумлення зображень з використанням REDNet

3.4. Підсумки

Далі для більш наглядного порівняння ефективності знешумлення кожною нейронною мережею, наведемо графіки оцінок PSNR та SSIM при роботі з Пуассонівським шумом. Шум Пуассона — це тип мультиплікативного шуму, який часто зустрічається в медичній візуалізації, тобто у програмах обробки зображень, де сигнал складається з підрахунків. Пуассонівський шум виникає внаслідок статистичних властивостей детектування фотонів і може бути описаний розподілом Пуассона. Оскільки шум Пуассона найбільш наближений до реально наявних шумів в МРТ зображеннях, які вже були згадані раніше, а також він є більш складним, ніж шум Гауса, оскільки він не є стаціонарним, його дисперсія пропорційна середньому значенню, і він демонструє значні коливання локальної інтенсивності, то доречніше буде зробити загальне порівняння обраних нейронних мереж саме по роботі з даним видом шуму.

По результатам оцінки всіх трьох мереж ми вже зробили висновок, що саме REDNet з його надлишковими з'єднаннями дав найкращі результати, проте для більшої наглядності на рисунках 15 та 16 представлено Порівняння результатів SSIM та PSNR оцінки нейронних мереж при роботі з Пуассонівським шумом.




Рис. 3.10. Порівняння результатів SSIM оцінки нейронних мереж при роботі з Пуассонівським шумом




Рисунок 16. Порівняння результатів PSNR оцінки нейронних мереж при роботі з Пуассонівським шумом

Як ми бачимо по рисунках 15 та 16, U-Net, хоч і має хороші результати на 1-5% шуму, вона сильно уступає REDNet та DnCNN, особливо це можна побачити по PSNR.

Пояснити це можна наступним чином. REDNet — це архітектура глибокої нейронної мережі, яка базується на залишковому навчанні, що дозволяє обробляти дуже глибокі мережі та покращувати потік інформації. Архітектура була спеціально розроблена для зменшення шуму та високої роздільної здатності медичних зображень, і вона включає серію залишкових блоків, оптимізованих для зменшення шуму. Архітектура також включає функції пакетної нормалізації та нелінійної активації, які додатково покращують продуктивність мережі.

Подібним чином, DnCNN — це архітектура глибокої нейронної мережі, яка була спеціально розроблена для усунення шумів у зображенні та використовує низку згорткових шарів для визначення зв'язку між зашумленими та чистими зображеннями. DnCNN оптимізовано для зменшення шуму та використовує залишкове навчання та пакетну нормалізацію для покращення продуктивності мережі.

У свою чергу U-Net хоч і є широко використовуваною та ефективною архітектурою для багатьох завдань обробки медичних зображень, включаючи усунення шумів, вона в першу чергу була створена для задач сегментації, тому вона і уступає. Проте, в теорії, вона може бути застосована до більшої кількості задач обробки медичних зображень.

4. Застосування REDNet для знешумлення медичних зображень з доданим шумом у k-простір.

4.1. Переведення dicom зображень в k-простір

K-простір — це «необроблені дані» для магнітно-резонансної томографії (МРТ) [19]. Дані, отримані сканером, збираються та впорядковуються всередині окремих масивів k-простору. Кожне окреме зображення отримується з матриці k-простору, наприклад, для одного зрізу, зображеного в 20 фазах серця, є 20 відповідних масивів k-простору. У більшості модальностей візуалізації кореляція між фізичною властивістю вибірки та способом, у який дані впорядковані для формування зображення, зазвичай інтуїтивно очевидна. У МРТ k-простір отримується, і зображення генерується у спосіб, який не є природним інтуїтивно зрозумілим.

Щоб перетворити зображення DICOM на дані k-space треба перетворити зображення DICOM на зображення з комплексними значеннями, застосовуючи до кожного зображення перетворення Фур'є. Перетворення Фур'є перетворює зображення просторової області в частотну область, а комплексні значення представляють амплітуду та фазу компонентів просторової частоти.

Далі комплекснозначні зображення упорядковуються в матрицю, яка відповідає даним k-простору. Розмір матриці повинен відповідати кількості вибірок у напрямках кодування частоти та фази. На рисунку 17 представлено оригінальне зображення та це зображення представлено у k-просторі.




Рис. 4.1. Оригінальне зображення(зліва) та зображення представлене у k-просторі(справа).

4.2. Оцінка якості знешумлення (PSNR та SSIM)

Як вже зазначалось раніше, в якості нейронної мережі, яка була адаптована для цієї задачі, була обрана REDNet. Далі представлено опис архітектури.

Архітектура RedNet складається з 30 згорткових шарів, включаючи 15 залишкових блоків з 2 згортковими шарами в кожному блоці. За кожним згортковим шаром слідує рівень пакетної нормалізації та функція активації випрямленої лінійної одиниці (ReLU). Вхід до мережі – це 3D-об’єм (висота x ширина x канали), який відповідає двовимірному зображенню (висота x ширина) з одним каналом. Вихід мережі також є тривимірним об’ємом тих самих розмірів, що й вхід, який представляє зображення з шумом.

В архітектурі RedNet використовується такий тип згорткового шару, що зветься розширеною згорткою, він дозволяє мережі збільшувати сприйнятливий поле без збільшення кількості параметрів.

Наступні гіперпараметри використовувалися в архітектурі RedNet для усунення шумів зображення DICOM:

- Розмір пакету(батча): 8. Тобто кількість вхідних зображень, які обробляються разом за один прохід вперед і назад нейронної мережі під час навчання був обраний рівний 8.
- Швидкість навчання: У цьому випадку використовувалася швидкість навчання $1e-3$. Варто зазначати, що вища швидкість навчання може призвести до швидшої конвергенції, але також може призвести до того, що модель випередить оптимальне рішення. Нижча швидкість навчання може призвести до повільної конвергенції, але може призвести до кращої продуктивності. Тому цей параметр важко підібрати.
- Функція втрат: використана функція втрат середньоквадратичної помилки (MSE), яка обчислює середнє значення квадратів різниць між прогнозованими та істинними результатами.
- Оптимізатор: Адам

На рисунках 18 та 19 представлено результати оцінки роботи такої нейронної мережі Гаусовим та Пуасонівським шумом у межах 1-3%, оскільки більший відсоток може призвести до значних змін у матриці i , відповідно, відновлення зображення можна бути вважати неможливим.

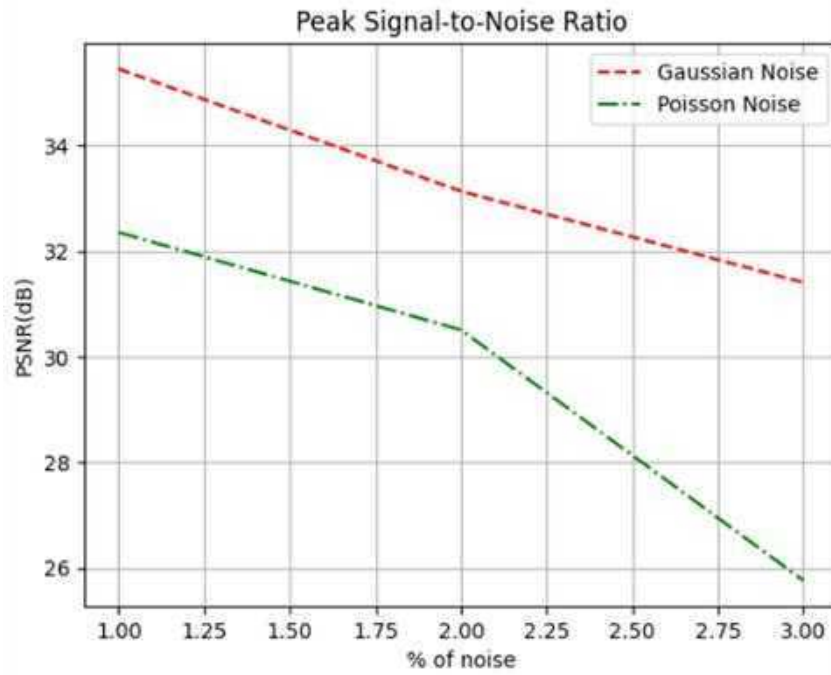


Рис. 4.2. Порівняння результатів PSNR для зображень K-області

PSNR (dB) REDNet k-space			
% of noise	1	2	3
Gaussian noise	35.46	33.14	31.41
Poisson noise	32.36	30.51	25.76

Табл. 4.1. Порівняння результатів PSNR для зображень K-області

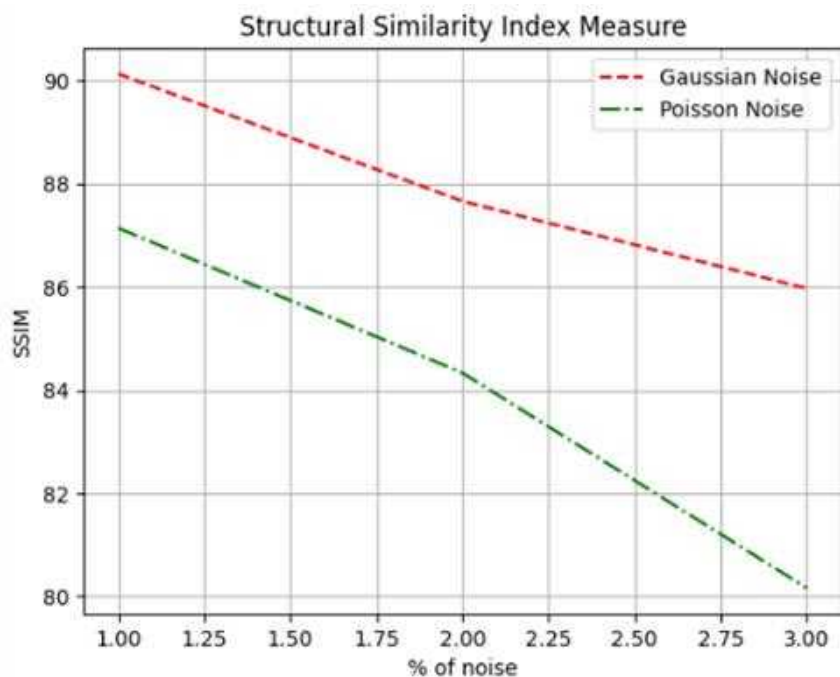


Рис. 4.3. Порівняння результатів SSIM для зображень K-області

SSIM REDNet k-space			
% of noise	1	2	3
Gaussian noise	90.13	87.66	85.97
Poisson noise	87.14	84.33	80.16

Табл. 4.2. Порівняння результатів SSIM для зображень K-області

Як видно з рисунків 18 та 19, можна сказати, що насправді спроба знешумити зображення на етапі математичного представлення просторової частотної області даних МРТ, але видно, що для більш складного типу шуму, тобто Пуасонівського, ми маємо різкий спад ефективності знешумлення, це пов'язано з тим, що більш складний характер шуму значно впливає на загальний вигляд області і саме відновлення зображення стає складнішим незалежно від відсотку шуму.

Проте при прямому використанні нейронної мережі до таких даних, як до звичаних зображень не дає бажаної ефективності, оскільки це більше складне представлення. Тож, для покращення можна розглянути такі моменти:

- Параметри збору даних: наприклад, щільність дискретизації, час відлуння, час повторення та поле зору, ці параметри можуть впливати на рівень шуму та відповідно на співвідношення сигнал/шум (SNR).
- Характеристики шуму: оскільки шум у k -просторі може бути складним і корельованим, а, отже важливо знати його статистичні властивості, як його спектр потужності та функція просторової кореляції.
- Вміст зображення: це також може впливати на процес усунення шумів. Наприклад, зображення з різкими краями або дрібними деталями можуть потребувати інших стратегій усунення шумів, ніж зображення з гладкими або однорідними областями.

Враховуючи вище зазначене, усунення шумів на цьому етапі потребує врахування більшої кількості параметрів, але це має свій потенціал.

Висновки

В цій роботі було представлено загальний огляд та використання одних з найбільш популярних нейронних мереж для усунення шуму – U-Net та DnCNN, та аналіз відносно нової архітектури REDNet яка ще не встигла стати популярною. Саме на використанні архітектури REDNet було зосереджено основну увагу, оскільки вона має низку переваг по відношенню до інших моделей в даній задачі. Аналізуючи результати роботи всіх трьох нейронних мереж, можна сказати що на більш простих шумах вони всі показують себе досить добре, проте, враховуючи їх результати на високих відсотках шуму та оцінку цих мереж з допомогою PSNR та SSIM особливо при роботі з імпульсним шумом/шумом «солі та перцю», можна сказати, що REDNet може мати більші перспективи для застосування на більш складних типах шуму, які присутні в МРТ зображеннях. Усі три нейронні мережі — DnCNN, U-Net і REDNet — можуть ефективно придушувати зображення, пошкоджені тепловим шумом, оскільки додатковий шум є одним із найпоширеніших типів шуму, і ці мережі можуть добре впоратися з ним. Але REDNet може краще підходити для зменшення шуму медичних зображень через здатність обробляти складніші шаблони та текстури шуму тому в теорії можна зменшити дробовий шум. Він може працювати з шумом дрейфу, оскільки вона може фіксувати тимчасові залежності в послідовності зображень.

Показано, що REDNet і DnCNN перевершують U-Net у задачах знешумлення медичних зображень, оскільки вони спеціально розроблені для цього завдання та включають особливі функції, які оптимізують їх продуктивність. Вони також мають вищий рівень глибини та складності порівняно з U-Net, що дозволяє їм вивчати складніші зв'язки між зашумленими та чистими зображеннями, що призводить до кращої продуктивності усунення шумів.

Додатково було розглянути можливість зменшити шум на етапі, коли ми ще не маємо зображення, а маємо матрицю з комплексними значеннями, що містить інформацію про взяття сигналу з різних частот у просторі, тобто k -простір. Але без додаткових модифікацій ця нейронна мережа не показала якихось значних результатів і ми отримали приблизно ту саму картину, що і при роботі з звичайними зображеннями, але тут ми використали лише шум до 3%, оскільки більший з високою імовірністю внесе надто багато змін в k -простір і після реконструкції зображення ми не отримуємо якоїсь чіткої картинки, тож, цей етап ще потребує доопрацювання.

Також варто зазначити, що насправді ці нейронні мережі можуть бути застосовані на ширший розгляд:

Зображеннях КТ (комп'ютерна томографія): на ці зображення може впливати шум, спричинений випромінюванням, яке використовується в процесі візуалізації.

Ультразвукових зображеннях: на ці зображення може впливати спекл-шум, спричинений інтерференцією звукових хвиль.

І, навіть, у військовій сфері, наприклад, детектуванні будь-яких об'єктів з дрону чи супутника, оскільки ці нейронні мережі можуть бути навчені як знешумленню, так і сегментації, тобто виділенню певних об'єктів серед інших по різним ознакам.

Тож, підсумовуючи, використання нейронних мереж для усунення шумів показало чудові результати, і потенціал для подальшого вдосконалення величезний. З розвитком більш досконалих архітектур глибокого навчання та методів навчання можна досягти ще кращих результатів. Крім того, застосування цих методів в інших сферах обробки зображень, може також показати

багатообіцяючі результати, що вже було представлено в різних роботах, а це робить цю область досліджень дуже захоплюючою з багатьма можливостями.

Список використаної літератури

- [1] Jiuxiang Gua, Zhenhua Wangb, Jason Kuenb, Lianyang Mab, Amir Shahroudyb, Bing Shuaib, Ting Liub, Xingxing Wangb, Li Wangb, Gang Wangb, Jianfei Caic, Tsuhan Chenc. Recent Advances in Convolutional Neural Networks. 2015.
- [2] Sebastian Ruder (2016). An overview of gradient descent optimisation algorithms.
- [3] Da-in Eun, Ryoungwoo Jang, Woo Seok Ha, Hyunna Lee, Seung Chai Jung & Namkug Kim. Deep-learning-based image quality enhancement of compressed sensing magnetic resonance imaging of vessel wall: comparison of self-supervised and unsupervised approaches August 2020, Scientific Reports 10(1):13950.
- [4] Nikolas Adaloglou. An overview of Unet architectures for semantic segmentation and biomedical image segmentation. on 2021.
- [5] K. Zhang, W. Zuo, Y. Chen, D. Meng and L. Zhang, "Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising," in IEEE Transactions on Image Processing, vol. 26, no. 7, pp. 3142-3155, July 2017, doi: 10.1109/TIP.2017.2662206.
- [6] Thung, K.-H. and Raveendran, P. (2009) A Survey of Image Quality Measures. IEEE Technical Postgraduates (TECHPOS) International Conference, Kuala Lumpur, 14-15 December 2009, 1-4.
- [7] Søgaard, J., Krasula, L., Shahid, M., Temel, D., Brunnstrom, K. and Razaak, M. (2016) Applicability of Existing Objective Metrics of Perceptual Quality for Adaptive Video Streaming. Society for Imaging Science and Technology IS&T International Symposium on Electronic Imaging.
- [8] Tanchenko, Alexander. (2014). Visual-PSNR measure of image quality. Journal of Visual Communication and Image Representation. 25. 10.1016/j.jvcir.2014.01.008.

- [9] Zhou Wang, Alan Conrad Bovik, Hamid Rahim Sheikh, and Eero P. Simoncelli. IEEE Image Quality Assessment: From Error Visibility to Structural Similarity. IEEE Transactions on image processing, vol. 13, No. 4, April 2004.
- [10] Wang, Zhou & Bovik, Alan & Sheikh, Hamid. (2005). Structural Similarity Based Image Quality Assessment. Digital Video Image Quality and Perceptual Coding, Ser. Series in Signal Processing and Communications. 10.1201/9781420027822.ch7.
- [11] Sanches, Joo M., Jacinto C. Nascimento, and Jorge S. Marques. "Medical image noise reduction using the SylvesterLyapunov equation." IEEE transactions on image processing 17.9 (2008): 1522-1539.
- [12] Kaur, Gurmeet & Kaur, Rupinder. (2012). Image De-Noising using Wavelet Transform and Various Filters. International Journal of Research in Computer Science. 2. 10.7815/ijorcs.22.2012.017.
- [13] Rodrigues, Isabel & Sanches, João & Bioucas-Dias, Jose. (2008). Denoising of medical images corrupted by Poisson noise. 1756 - 1759. 10.1109/ICIP.2008.4712115.
- [14] Lin, TC & Yu, PT. (2006). Salt-Pepper Impulse Noise Detection and Removal Using Multiple Thresholds for Image Restoration. Journal of Information Science and Engineering. 22. 189-198.
- [15] Xu, Wenna & Deng, Xinping & Guo, Shanxin & Chen, Jinsong & Sun, Luyi & Zheng, Xiaorou & Xiong, Yingfei & Shen, Yuan & Wang, Xiaoqin. (2020). High-

Resolution U-Net: Preserving Image Details for Cultivated Land Extraction. *Sensors*. 20. 4064. 10.3390/s20154064.

[16] T. S. Sharan, R. Bhattacharjee, S. Sharma and N. Sharma, "Evaluation of Deep Learning Methods (DnCNN and U-Net) for Denoising of Heart Auscultation Signals," 2020 3rd International Conference on Communication System, Computing and IT Applications (CSCITA), Mumbai, India, 2020, pp. 151-155, doi: 10.1109/CSCITA47329.2020.9137813.

[17] Zhang K, Zuo W, Chen Y, Meng D, Zhang L. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Trans Image Process*. 2017 Jul;26(7):3142-3155. doi: 10.1109/TIP.2017.2662206. Epub 2017 Feb 1. PMID: 28166495.

[18] Prabhat KC, Rongping Zeng, M. Mehdi Farhangi, Kyle J. Myers. Deep neural networks-based denoising models for CT imaging and their efficacy. *Proceedings Volume 11595, Medical Imaging 2021: Physics of Medical Imaging; 115950H (2021)* <https://doi.org/10.1117/12.2581418>.

[19] Sykora, Stan. (2005). K-space formulation of MRI. 10.3247/SL1Mri05.001.