

УДК 004.932:616

## КЛАСИФІКАЦІЯ ЗОБРАЖЕНЬ ЛЕГЕНЬ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ

І. В. Піх<sup>1,2</sup>, Н. М. Михайлович<sup>1</sup>, К. Ю. Познухов<sup>1</sup>

<sup>1</sup>Українська академія друкарства,  
вул. Під Голоском, 19, Львів, 79020, Україна,

<sup>2</sup>Національний університет «Львівська політехніка»,  
вул. Степана Бандери, 12, Львів, 79013, Україна

*Розглянуто проблему класифікації зображень легень людини для медичної діагностики з використанням нейронних мереж. Проаналізовано попередні дослідження, в яких використовувалися різні архітектури нейронних мереж. Визначено методи підготовки даних, які допомагають забезпечити якісну інформацію для навчання нейронної мережі і покращують її ефективність. Описано процес навчання нейронної мережі, зокрема методи оптимізації та контроль перенавчання. Проведено валідацію моделі та оцінку її ефективності за допомогою розрахунку різних метрик, таких як точність, чутливість і специфічність. Наведено результати досліджень та порівнянь різних факторів, які впливають на реалізацію нейронних мереж.*

**Ключові слова:** нейронні мережі, класифікація зображень, медична діагностика, глибоке навчання, валідація моделі, оцінка ефективності, метрики ефективності, крос-валідація, матриця помилок, аналіз помилок, підготовка даних для навчання, розширення набору даних.

**Постановка проблеми.** Класифікація зображень легень людини є важливою задачею у медичній діагностиці. Під час розпізнавання різних захворювань, таких як пухлини, запалення легенів, туберкульоз тощо, аналіз зображень легень може надати цінну інформацію для лікарів та допомогти вчасно виявити та лікувати хвороби.

Однак ручна обробка та аналіз великого обсягу зображень легень є складною задачею для медичного персоналу. Тут на допомогу приходять нейронні мережі, які здатні автоматично класифікувати зображення легень та допомагати у діагностиці.

**Мета статті** — здійснити огляд використання нейронних мереж для класифікації зображень легень та їх значення у виявленні захворювань. Розглянути попередні дослідження з цієї галузі, архітектури нейронних мереж, методи підготовки даних, процес навчання мережі, валідація моделі та її оцінка. Також будуть розглянуті можливі застосування нейронних мереж у медицині та перспективи подальших досліджень.

### **Значення класифікації зображень легень для виявлення захворювань.**

Класифікація зображень легень має велике значення у медицині для виявлення та діагностики різних захворювань. Завдяки точній та швидкій класифікації нейронні мережі можуть виявити аномалії та патологічні зміни на зображеннях легень, що може допомогти медичному персоналу у вчасному поставленні діагнозу та ефективному лікуванні.

Окрім того, класифікація зображень легень за допомогою нейронних мереж дає змогу здійснювати автоматичний аналіз великого обсягу даних, що значно збільшує швидкість та ефективність процесу діагностики. Це особливо важливо в умовах великої кількості зображень, які отримують в межах скринінгових програм та медичних досліджень.

Застосування нейронних мереж для класифікації зображень легень також дає змогу покращити об'єктивність та уніфікацію діагностики. Людський фактор та індивідуальні впливи можуть призводити до неточностей та розбіжностей у діагнозах, тоді як автоматична система, яка базується на об'єктивних алгоритмах, може забезпечити більш однорідну та надійну оцінку.

**Вивчення попередніх досліджень з використання нейронних мереж для класифікації зображень легень.** Проведемо огляд попередніх досліджень, які використовують нейронні мережі для класифікації зображень легень. Ці дослідження дають змогу отримати уявлення про поточний стан цієї сфери та наявні підходи.

Одним з визнаних досліджень є стаття «Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?» авторів N. Tajbakhsh, J. Y. Shin, S. R. Gurudu та ін. У ній автори досліджують використання глибоких згорткових нейронних мереж для виявлення пухлин в легенях на зображеннях. Результати дослідження показали високу точність та чутливість при використанні нейронних мереж [1].

Ще одне важливе дослідження у цій сфері — «CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning» P. Rajpurkar, J. Irvin, K. Zhu та ін. У ньому автори пропонують модель глибокої нейронної мережі, яка може виявляти пневмонію на рентгенівських знімках легень. Дослідження показали високу точність та результати порівнянь [2].

Крім того, варто виокремити працю «Automatic Detection of COVID-19 from Chest X-ray Images using Deep Learning» авторів H. Hemdan, M. Shouman, M. Karar та ін., де використовується глибоке навчання для автоматичного виявлення COVID-19 на рентгенівських знімках легень. Результати показали великий потенціал глибоких нейронних мереж у ранньому виявленні цього захворювання [3].

Ці приклади попередніх досліджень ілюструють значний прогрес, досягнутий у використанні нейронних мереж для класифікації зображень легень. Продовження досліджень у цій сфері відкриває шлях до покращення діагностики та лікування різних захворювань легень.

**Огляд різних архітектур нейронних мереж, використаних у схожих дослідженнях.** Розглянуто різні архітектури нейронних мереж, які використовуються у схожих дослідженнях з класифікації зображень легень. Ці архітектури є центральними у досягненні високої точності та надійності результатів.

Одні з найпоширеніших архітектур нейронних мереж для класифікації зображень легень є згорткові нейронні мережі (Convolutional Neural Networks, CNN). Вони використовують спеціальні шари, такі як згорткові шари та пулінгові шари, для ефективного виявлення ознак у зображеннях легень. Ці архітектури дають змогу автоматично вивчати набори ознак, що допомагає у точній класифікації.

Деякі з відомих архітектур CNN, які були успішно використані в дослідженнях класифікації зображень легень, включають AlexNet, VGGNet, ResNet та InceptionNet. Кожна з цих архітектур має свої особливості і використовує різні комбінації шарів та функцій активації для досягнення високої точності.

Крім згорткових нейронних мереж, використання попередньо навчених моделей також є популярним підходом у класифікації зображень легень. Попередньо навчені моделі, такі як ResNet, InceptionNet та MobileNet, розроблені для вирішення загальних завдань класифікації зображень на великих наборах даних, можуть бути використані в контексті класифікації зображень легень. Вони демонструють високу ефективність та можуть прискорити процес навчання, особливо при обмежених ресурсах.

Також варто вказати, що з'явилися архітектури, спеціально розроблені для аналізу зображень медичних досліджень, зокрема зображень легень. Наприклад, архітектура CheXNet, розглянута у вищезгаданій праці, спеціально створена для виявлення пневмонії на рентгенівських знімках. Ці спеціалізовані архітектури можуть виявляти більш точні ознаки та досягати кращих результатів у класифікації зображень легень [4].

Продовження досліджень у цій галузі може призвести до ще більш ефективних та точних методів класифікації.

**Обговорення методів підготовки даних та досягнутих результатів.** Підготовка даних є важливим етапом у будь-якому дослідженні з використанням нейронних мереж. Для класифікації зображень легень насамперед необхідно мати доступ до великого набору медичних зображень легень, які належать до різних класів (наприклад, здорові легені, легені з пневмонією, туберкульозом тощо). Ці зображення можуть бути отримані з рентгенівських знімків, КТ-знімків або МРТ-знімків.

Під час підготовки даних необхідно враховувати декілька аспектів. Спочатку зображення легень можуть бути різного розміру та роздільної здатності. Тому їх необхідно нормалізувати та вирівняти до одного стандартного розміру перед подальшою обробкою нейронною мережею. Для цього можна застосувати методи ресайзу або обрізки зображень.

Крім того, аугментація даних може бути використана для розширення набору даних. Це означає застосування різних перетворень до існуючих зображень, таких як обертання, зміщення, зміна контрастності тощо. Це допомагає уникнути перенавчання та збільшити різноманітність даних, що може покращити результати класифікації.

Після підготовки даних проводиться навчання нейронної мережі. Для цього використовуються різні методи оптимізації, зокрема стохастичний градієнтний

спуск та адаптивні оптимізатори, які допомагають знаходити оптимальні ваги мережі.

Оцінка результатів проводиться за допомогою валідації моделі на тестовому наборі даних. Метрики ефективності, такі як точність (accuracy), чутливість (sensitivity), специфічність (specificity) та F-оцінка (F1-score), використовуються для оцінки продуктивності моделі. Крос-валідація може бути використана для оцінки стійкості та узагальнювальної здатності моделі.

**Пояснення загального принципу роботи нейронних мереж для класифікації зображень.** Нейронні мережі є потужним інструментом для класифікації зображень, зокрема зображень легень. Вони імітують роботу людського мозку, де нейрони співпрацюють, щоб обробляти та розпізнавати різні ознаки у вхідних даних.

Основний принцип роботи нейронної мережі полягає у передачі даних через набір шарів нейронів. Кожен шар містить набір нейронів, які обчислюють ваговану суму вхідних даних за допомогою ваг та активаційних функцій. Результат обчислення нейрона передається до наступного шару, де проводяться подібні операції.

Зазвичай у задачах класифікації зображень легень використовуються згорткові нейронні мережі (Convolutional Neural Networks, CNN). Вони ефективно працюють з двовимірними зображеннями, оскільки враховують просторові залежності ознак у зображенні. Згорткові шари нейронної мережі використовують фільтри, що ковзають по зображенню, для виявлення локальних ознак, таких як краї, текстури або форми.

Після згорткових шарів використовуються шари пулінгу, які зменшують просторовий розмір ознак та забезпечують інваріантність до масштабу та зсуву. Повноз'язні шари, що знаходяться в кінці нейронної мережі, використовуються для класифікації, де кожен нейрон представляє окремий клас або категорію.

Крім згорткових нейронних мереж, також можуть бути використані попередньо навчені моделі (pre-trained models), які навчені на великих наборах даних, наприклад ImageNet. Ці моделі вже мають здатність розпізнавати загальні ознаки зображень і можуть бути доопрацьовані або додатково налаштовані для класифікації зображень легень.

Загальний принцип роботи нейронних мереж для класифікації зображень легень полягає у поєднанні згорткових шарів для виявлення локальних ознак та повноз'язних шарів для класифікації. Ця архітектура дає змогу нейронній мережі автоматично вивчати та розпізнавати різні ознаки, що допомагає в точній класифікації зображень легень.

**Огляд основних компонентів архітектури нейронної мережі.** Архітектура нейронної мережі для класифікації зображень легень містить кілька основних компонентів, які співпрацюють для досягнення високої точності та ефективності. Давайте розглянемо ці компоненти детальніше:

1. Згорткові шари (Convolutional Layers) — використовуються для виявлення локальних ознак у зображеннях. Кожен нейрон у згортковому шарі виконує операцію згортки, де він обчислює ваговану суму значень пікселів у вікні, що ковзає по зображенню. Це дає змогу виявляти різні ознаки, такі як краї, текстури або форми.

2. Функції активації (Activation Functions) — введені після згорткових шарів для введення нелінійності в мережу. Вони допомагають моделі навчитися складним неоднорідним залежностям у даних. Деякі поширені функції активації включають ReLU (Rectified Linear Unit), Sigmoid та Tanh.

3. Пулінг (Pooling) — після згорткових шарів застосовуються шари пулінгу, які допомагають зменшити просторовий розмір ознак і знизити кількість параметрів в мережі. Пулінг виконує підвибірку значень з вихідного шару і обчислює статистичні характеристики, такі як максимум або середнє значення, для отримання зведеної інформації про важливі ознаки.

4. Повнозв'язні шари (Fully Connected Layers) — розташовані в кінці мережі і використовуються для класифікації. Кожен нейрон у повнозв'язному шарі пов'язаний з усіма нейронами попереднього шару. Ці шари обчислюють ваговану суму вхідних значень і застосовують функцію активації для отримання оцінок ймовірностей різних класів.

**Опис процесу препроцесингу та підготовки даних.** Процес препроцесингу та підготовки даних є важливим етапом перед подальшою обробкою зображень легень нейронною мережею. Цей етап передбачає кілька кроків, які допомагають забезпечити якість та надійність вхідних даних. Основні кроки препроцесингу та підготовки даних:

1. Завантаження даних — спочатку необхідно завантажити набір даних із зображеннями легень, який буде використовуватися для навчання та тестування моделі.

2. Перегляд та очищення даних — важливо переглянути дані та впевнитися, що вони відповідають очікуваному формату та якості. Якщо виявляються аномалії або пошкоджені зображення, їх потрібно видалити або відновити за допомогою відповідних методів.

3. Нормалізація даних — містить масштабування значень пікселів зображень для забезпечення однорідності та зручності обробки. Це може включати стандартизацію значень пікселів або нормалізацію до певного діапазону значень.

4. Вирівнювання розмірів зображень — для ефективної обробки зображень в нейронній мережі рекомендується вирівнювати розміри всіх зображень. Це можна зробити шляхом зміни розмірів зображень до єдиного стандартного розміру або використовуючи методи обрізки чи заповнення.

5. Аугментація даних — це процес створення нових зображень шляхом використання трансформацій, які зберігають контекст та класифікаційну інформацію. Це може включати зміну розміру, поворот, зсув, зміну контрастності та яскравості зображення. Аугментація даних допомагає розширити набір даних і зменшити ризик перенавчання моделі.

6. Розбиття даних на тренувальні, валідаційні та тестові набори — для оцінки ефективності моделі і попередження перенавчання набір даних зазвичай розділяють на тренувальний, валідаційний та тестовий набори. Тренувальний набір використовується для навчання моделі, валідаційний — для налаштування гіперпараметрів і оцінки ефективності, а тестовий — для остаточної оцінки моделі.

Процес препроцесингу та підготовки даних є необхідним кроком перед навчанням нейронної мережі для класифікації зображень легень. Це допомагає забезпечити якість та достовірність даних, а також поліпшити продуктивність та точність моделі.

**Нормалізація даних.** Нормалізація даних є важливим кроком перед навчанням моделі класифікації зображень легень. Її мета полягає в приведенні значень пікселів до стандартного діапазону, зазвичай від 0 до 1 або -1 до 1. Це полегшує процес навчання моделі, сприяє швидшій збіжності та допомагає уникнути некоректної ваги певних функцій.

Одними із поширених методів нормалізації є центрування та масштабування. Центрування полягає у відніманні середнього значення від кожного пікселя, щоб центрувати дані навколо нуля. Масштабування виконується шляхом поділу кожного пікселя на стандартне відхилення, щоб змінити діапазон значень на одиничний.

Додатковими методами нормалізації можуть бути мінімакс нормалізація, де значення пікселів масштабуються до певного діапазону, або Z-нормалізація, яка використовує стандартне відхилення та середнє значення для нормалізації даних.

**Вирівнювання розмірів зображень.** Вирівнювання розмірів зображень є необхідним кроком для забезпечення однакового розміру вхідних даних перед подачею їх на вхід нейронній мережі. Це важливо, оскільки багато архітектур нейронних мереж, зокрема згорткові нейронні мережі (Convolutional Neural Networks), вимагають однакових розмірів зображень.

Існує кілька підходів до вирівнювання розмірів зображень. Один із них — зміна розміру зображень шляхом збільшення або зменшення їх роздільної здатності до одного заданого розміру. Це можна зробити за допомогою ресемплінгу або інтерполяції методами, такими як білінійна або бікубічна інтерполяція.

Інший підхід — вирізання частини зображення, що має заданий розмір, для створення єдиного розміру вхідних даних. Наприклад, можна вирізати центральну область зображення або використовувати методи областей інтересу (Region of Interest — ROI), де виділяються певні області зображення, що містять важливу інформацію про легені.

**Аугментація даних.** Аугментація даних — це процес розширення набору даних шляхом генерації нових прикладів з існуючих зображень. Цей метод має кілька переваг, зокрема запобігає перенавчанню моделі, допомагає вирішити проблему недостатнього обсягу даних та покращує загальну роботу моделі на реальних даних.

Аугментація даних може містити різні операції над зображеннями, такі як зміна розміру, поворот, зсув, зміна контрастності, яскравості, насиченості, розмивання тощо. Наприклад, зображення можна повернути на певний кут, щоб змодельовати різні орієнтації легень, або можна збільшити розмір даних шляхом додавання шуму або застосування фільтрів.

Крім того, аугментація даних може включати генерацію додаткових прикладів, використовуючи трансформації зображень, такі як дзеркальне відображення або зміщення об'єктів на зображенні.

Важливо зазначити, що під час використання аугментації даних потрібно забезпечити реалістичність та зберегти суттєві характеристики зображень легень, щоб модель правильно навчалась на реальних даних [5].

**Важливість правильного підбору даних та збалансованості класів.** У контексті класифікації зображень легень для медичної діагностики правильний підбір даних та збалансованість класів є критичними факторами. Це впливає на якість навчання моделі і здатність до правильної класифікації різних захворювань.

Один із аспектів правильного підбору даних полягає в уникненні наявності помилкових або некоректно позначених зображень. Неналежно позначені зображення можуть призводити до неправильного навчання моделі та спотворення результатів. Тому перед використанням даних необхідно провести якісну перевірку та очистку датасету.

Збалансованість класів також є важливим аспектом. Це означає, що кількість зображень у кожному класі має бути приблизно однаковою. Якщо один клас має набагато менше зображень, порівняно з іншими, це може призвести до неправильного навчання моделі та спотворення результатів класифікації. Варто звернути особливу увагу на збалансованість класів, особливо якщо деякі захворювання рідкісніші або менш представлені в датасеті.

Додатковою стратегією може бути використання технік збільшення кількості зображень для менш представлених класів. Це можна зробити шляхом аугментації даних або штучного створення нових прикладів зображень для цих класів. Це допоможе підвищити представленість менш представлених класів і покращити здатність моделі до правильної класифікації.

Загалом правильний підбір даних та збалансованість класів є важливими етапами в підготовці даних для класифікації зображень легень. Це допомагає забезпечити якісне навчання моделі та досягнення надійних результатів у медичній діагностиці.

**Детальний опис процесу навчання нейронної мережі для класифікації зображень легень.** Навчання нейронної мережі для класифікації зображень легень включає кілька важливих етапів:

1. Підготовка даних. Спочатку необхідно підготувати дані для навчання. Це передбачає поділ датасету на тренувальний, валідаційний та тестовий набори, зчитування зображень з диска або використання готових функцій для завантаження даних, а також їхню нормалізацію та попередню обробку.

2. Вибір архітектури мережі. Потрібно вибрати відповідну архітектуру нейронної мережі для класифікації зображень легень. Зазвичай використовуються згорткові нейронні мережі (Convolutional Neural Networks, CNN), які добре справляються з обробкою зображень. Важливо визначити кількість шарів, розмір фільтрів, кількість нейронів у шарах та інші параметри архітектури.

3. Ініціалізація моделі. Перед початком навчання необхідно ініціалізувати ваги моделі. Це може бути випадкова ініціалізація або використання попередньо навченої моделі (pre-trained model), яка була попередньо навчена на великому наборі зображень, наприклад на ImageNet.

4. Навчання моделі. Навчання полягає у поступовій оптимізації ваг моделі з використанням тренувальних даних. Зазвичай використовується алгоритм стохастичного градієнтного спуску (Stochastic Gradient Descent, SGD) або його варіанти. На кожному кроці навчання обчислюється втрата (loss), і градієнти від цієї втрати використовуються для оновлення ваг моделі. Навчання триває доти, доки модель не досягне заданої точності або стійкості.

5. Оптимізація гіперпараметрів. Під час навчання моделі необхідно налаштувати різні гіперпараметри, такі як швидкість навчання (learning rate), розмір пакета (batch size), кількість епох навчання (number of epochs) та інші. Це важливий етап, що потребує експериментів та оцінки результатів на валідаційному наборі для знаходження оптимальних значень гіперпараметрів.

6. Контроль перенавчання (overfitting). Перенавчання є типовою проблемою при навчанні нейронних мереж. Для його уникнення можна використовувати методи регуляризації, такі як зниження швидкості навчання, додавання dropout-шарів або використання регуляризації ваг.

7. Збереження моделі. Після завершення навчання важливо зберегти навчену модель, щоб її можна було використовувати для класифікації нових зображень легень.

Це загальний опис процесу навчання нейронної мережі для класифікації зображень легень. Конкретні деталі та параметри можуть залежати від використовуваного фреймворку та архітектури моделі.

**Обговорення методів оптимізації, таких як стохастичний градієнтний спуск та адаптивні оптимізатори.** Під час навчання нейронної мережі для класифікації зображень легень використовуються різні методи оптимізації, які допомагають знайти оптимальні ваги моделі. Основні методи оптимізації містять:

1. Стохастичний градієнтний спуск (Stochastic Gradient Descent, SGD). Це один з найпоширеніших методів оптимізації, який використовує градієнти втрати для оновлення ваг моделі. У процесі навчання вибираються випадкові пакети даних (mini-batches), і для кожного пакета обчислюються градієнти та оновлюються ваги моделі.

2. Адаптивні оптимізатори. Ці методи оптимізації покращують стандартний SGD, дозволяючи адаптувати швидкість навчання для кожного параметра моделі окремо. Декілька популярних адаптивних оптимізаторів містять:

- Adam (Adaptive Moment Estimation) — цей оптимізатор поєднує переваги методу RMSprop та моменту Нестерова. Він використовує адаптивні швидкості навчання для кожного параметра та враховує експоненціально згладжені середні градієнтів та їх квадрати для оновлення ваг.
- AdaGrad (Adaptive Gradient) — цей метод налаштовує швидкість навчання для кожного параметра, враховуючи історію градієнтів. Він надає більший вплив на параметри, які мають великі градієнти, і менший вплив на параметри з малими градієнтами.
- RMSprop (Root Mean Square Propagation) — цей метод також адаптує швидкість навчання для кожного параметра, використовуючи експоненціально згладжені середні квадрати градієнтів. Він використовує згладжування, щоб зменшити вплив старих градієнтів та надати більший вплив останнім градієнтам.



Ці методи оптимізації дають змогу покращити швидкість збіжності моделі та уникнути проблем перенавчання. Вибір конкретного оптимізатора може залежати від архітектури моделі, розміру даних та інших факторів і потребує експериментування та налаштування гіперпараметрів.

**Вказівки щодо важливості налаштування гіперпараметрів та контролю перенавчання (overfitting).** Під час тренування нейронної мережі для класифікації зображень легень налаштування гіперпараметрів та контроль перенавчання є важливими кроками для досягнення оптимальної моделі. Ось кілька вказівок, які допоможуть забезпечити ефективне навчання та уникнути перенавчання:

1. Вибір оптимальної швидкості навчання — швидкість навчання (learning rate) визначає, як швидко змінюються ваги моделі під час процесу навчання. Занадто велика швидкість навчання може призвести до нестабільності та незбалансованості моделі, тоді як занадто мала швидкість може уповільнити процес навчання. Важливо експериментувати з різними значеннями швидкості навчання та знайти оптимальне значення для вашої конкретної моделі та даних.

2. Регуляризація є методом контролю перенавчання шляхом додавання додаткових штрафів до функції втрати. Найпоширенішими методами регуляризації є L1 та L2 регуляризація. Вони допомагають уникнути надмірного прилаштування моделі до тренувальних даних та покращують її загальну здатність до узагальнення на нові дані.

3. Контроль розміру мережі — розмір нейронної мережі має великий вплив на ефективність навчання. Занадто велика мережа може спричинити перенавчання, тоді як занадто мала мережа може бути недостатньою для моделювання складних залежностей в даних. Важливо збалансувати кількість шарів та нейронів у мережі залежно від складності завдання та розміру даних.

4. Використання регуляризації відбору ознак — регуляризація відбору ознак (feature selection) дає змогу вибрати найважливіші ознаки для класифікації зображень легень. Це допомагає зменшити розмір вхідних даних та покращити швидкість та ефективність навчання моделі.

5. Використання методів ансамблю, такі як злиття моделей (model ensembling) або багат шаровий перцептрон (multilayer perceptron), можуть покращити результати класифікації шляхом комбінування прогнозів з кількох незалежних моделей. Це дає змогу зменшити варіативність та покращити стійкість моделі.

Враховуючи ці вказівки, ви зможете ефективно налаштувати гіперпараметри та контролювати перенавчання вашої нейронної мережі для класифікації зображень легень.

**Пояснення методів валідації моделі та обчислення метрик ефективності, таких як точність (accuracy), чутливість (sensitivity), специфічність (specificity) тощо.** Після тренування моделі для класифікації зображень легень важливо провести валідацію, щоб оцінити її ефективність та здатність до узагальнення на нові дані. Для цього застосовуються різні методи валідації та обчислення метрик ефективності. Ось декілька основних методів та метрик, які можуть бути використані:

1. Розділення даних на тренувальний та тестовий набори — цей метод полягає в тому, щоб розділити наявні дані на дві частини — тренувальний набір для навчання моделі і тестовий набір для оцінки її ефективності. Тестовий набір має бути незалежним від тренувального набору і містити нові дані, які модель не бачила під час навчання.

2. Крос-валідація — цей метод дає змогу більш точно оцінити ефективність моделі шляхом поділу наявних даних на кілька частин (фолдів) і використання їх по черзі як тренувального та тестового наборів. Потім обчислюється середня метрика ефективності для всіх фолдів. Крос-валідація дає змогу отримати більш об'єктивну оцінку ефективності моделі та зменшує вплив випадкових факторів.

3. Метрики ефективності — метрики є числовими значеннями, які використовуються для оцінки ефективності класифікатора. Декілька загальних метрик, які можуть бути використані для класифікації зображень легень, включають:

- Точність (Accuracy) — вимірює загальну точність класифікатора, яка обчислюється як відношення правильно класифікованих зразків до загальної кількості зразків.
- Чутливість (Sensitivity) — вимірює здатність класифікатора правильно визначати позитивні зразки. Це відношення правильно визначених позитивних зразків до загальної кількості позитивних зразків.
- Специфічність (Specificity) — вимірює здатність класифікатора правильно визначати негативні зразки. Це відношення правильно визначених негативних зразків до загальної кількості негативних зразків.
- F-оцінка (F-measure) — комбінує точність та чутливість і використовується для оцінки збалансованості моделі. Вона обчислюється як гармонічне середнє точності та чутливості.
- Крива ROC (Receiver Operating Characteristic) — це графік, який відображає залежність між чутливістю та специфічністю класифікатора при різних порогових значеннях. Ця крива дає змогу визначити оптимальний поріг для класифікації.

Правильний вибір методів валідації та метрик ефективності допоможе оцінити якість та стійкість моделі для класифікації зображень легень.

**Обговорення крос-валідації та розбиття даних на тренувальні та тестові набори.** Одним з ключових аспектів оцінки ефективності моделі для класифікації зображень легень є правильне розбиття наявних даних на тренувальний та тестовий набори. Розбиття даних допомагає визначити, наскільки добре модель здатна узагальнювати нові дані, які вона не бачила під час навчання. Два поширені підходи до розбиття даних — це крос-валідація та випадкове розбиття.

1. Крос-валідація. Цей підхід використовується для кращої оцінки ефективності моделі шляхом поділу даних на кілька фолдів. Наприклад, популярним варіантом є «*k-fold cross-validation*», де дані розбиваються на *k* рівних частин (фолдів). Далі модель навчається на *k-1* фолдах, а потім перевіряється на залишковому фолді. Цей процес повторюється *k* разів, змінюючи фолд, на якому проводиться перевірка. Завершально обчислюється середнє значення метрик ефективності по всіх фолдах.

Крос-валідація дає змогу отримати більш об'єктивну оцінку ефективності моделі, оскільки враховується варіація результатів на різних підмножинах даних.

2. Випадкове розбиття. Інший підхід полягає в простому випадковому розбитті даних на тренувальний та тестовий набори. Зазвичай відсоток даних, призначених для тестування, визначається заздалегідь, наприклад 70% даних для тренування та 30% для тестування. Важливо враховувати, що розбиття має бути випадковим, щоб уникнути впливу будь-яких специфічних шаблонів чи порядку даних на результати оцінки моделі.

Обидва підходи мають свої переваги та недоліки, їх вибір залежить від конкретного дослідження та його вимог. Крос-валідація зазвичай забезпечує більш об'єктивну оцінку моделі, але може бути витратною з точки зору обчислювальних ресурсів. Випадкове розбиття є простим і швидким підходом, але може бути менш стійким, особливо при обмеженій кількості даних.

Окрім цього, для кращого узагальнення моделі можна використовувати додаткові методи підготовки даних, такі як аугментація даних, що дає змогу штучно розширити набір даних шляхом застосування різних перетворень до існуючих зображень.

**Валідація та оцінка моделі.** Після навчання моделі для класифікації зображень легень важливо провести її валідацію та оцінку, щоб оцінити її ефективність та здатність правильно класифікувати нові зображення. Для цього використовуються різні метрики та підходи. Основні методи валідації та оцінки моделі включають:

1. Розбиття на тренувальний, валідаційний та тестовий набори. Тренувальний набір використовується для навчання моделі, валідаційний набір використовується для налаштування гіперпараметрів та оцінки ефективності моделі під час навчання, а тестовий набір — для оцінки остаточної ефективності моделі після завершення навчання.

2. Метрики ефективності. Для оцінки ефективності моделі використовуються різні метрики, які вимірюють рівень точності та надійності класифікації. Деякі з поширених метрик включають точність (accuracy), чутливість (sensitivity), специфічність (specificity), F1-оцінку (F1-score) та площу під ROC-кривою (ROC-AUC).

3. Крос-валідація є методом оцінки ефективності моделі, який використовує розбиття даних на кілька фолдів. Вона дає змогу отримати більш об'єктивну оцінку шляхом перевірки моделі на різних комбінаціях тренувальних та валідаційних наборів.

4. Матриця помилок — використовується для візуалізації результатів класифікації моделі. Вона вказує кількість правильно та неправильно класифікованих зображень для кожного класу.

5. Аналіз помилок. Дослідження та аналіз помилок, зроблених моделлю, може допомогти виявити проблемні області та вдосконалити модель. Важливо розуміти причини помилок та вживати заходів для їх усунення.

Валідація та оцінка моделі дозволяють зрозуміти її ефективність та надійність перед застосуванням у реальних умовах. Це допомагає підтвердити, що модель

відповідає поставленим медичним вимогам та може бути використана для класифікації зображень легень з високою точністю та надійністю.

**Потенційні застосування нейронних мереж для класифікації зображень легень у медицині.** Застосування нейронних мереж для класифікації зображень легень має значний потенціал у медицині та медичній діагностиці. Деякі з можливих застосувань:

1. Виявлення ранніх ознак захворювань — нейронні мережі можуть допомогти виявити ранні ознаки захворювань легень, навіть до появи симптомів. Це дає змогу медичним фахівцям почати лікування на ранній стадії, що покращує прогноз та шанси на одужання пацієнтів.

2. Підтримка в прийнятті рішень — нейронні мережі можуть слугувати як допоміжний інструмент для медичних фахівців під час прийняття рішень щодо діагностики та лікування. Вони можуть надати об'єктивну оцінку ймовірності наявності певного захворювання, що допомагає підтвердити чи виключити деякі діагнози.

3. Автоматизована скринінгова система — нейронні мережі можуть бути використані для створення автоматизованих систем скринінгу, які можуть швидко та ефективно аналізувати великий обсяг зображень легень. Це допомагає виявити потенційні захворювання у великій кількості пацієнтів та спрямувати їх на подальшу діагностику та лікування.

4. Персоналізована медицина — використання нейронних мереж дає змогу створити моделі, які враховують індивідуальні особливості кожного пацієнта. Це дає змогу розробляти персоналізовані підходи до діагностики та лікування захворювань легень, забезпечуючи оптимальні результати та знижуючи негативні наслідки.

5. Моніторинг стану хворих — нейронні мережі можуть бути використані для постійного моніторингу стану хворих із захворюваннями легень. Завдяки аналізу зображень легень можна відстежувати динаміку захворювання, контролювати ефективність лікування та вчасно реагувати на зміни у стані пацієнта.

Ці застосування нейронних мереж для класифікації зображень легень у медицині є лише початком, існують безліч можливостей для подальшого розвитку та досліджень. Застосування штучного інтелекту в медицині може бути корисним та сприяти покращенню якості медичної діагностики та лікування [6].

**Розгляд можливих поліпшень та додаткових досліджень.** Незважаючи на значні досягнення використання нейронних мереж для класифікації зображень легень у медицині, ще існує кілька аспектів, які можуть бути покращені та потребують подальших досліджень. Ось деякі з них:

1. Розширення набору даних — для досягнення більш точних та надійних результатів потрібно мати широкий та репрезентативний набір даних. Важливо збирати більше зображень легень з різними захворюваннями та різними факторами, що можуть впливати на зображення (наприклад, вік, стать, розмір тіла). Це дасть змогу збільшити робастність моделей та знизити ризик помилкових діагнозів.

2. Врахування контексту — покращення класифікації зображень легень можна досягти шляхом врахування контексту та взаємозв'язків між різними зображеннями.

Наприклад, врахування змін у зображеннях з попередніх обстежень може допомогти виявити динаміку розвитку захворювання та прогнозувати результати.

3. Вдосконалення архітектур — надалі можна досліджувати та вдосконалювати архітектури нейронних мереж для класифікації зображень легень. Це може включати використання більш складних та глибоких моделей, а також комбінування різних типів архітектур для досягнення кращої ефективності та точності.

4. Забезпечення пояснюваності — важливим аспектом використання нейронних мереж у медицині є забезпечення пояснюваності результатів. Подальші дослідження повинні спрямовуватися на розробку методів, які дозволяють розуміти, як саме модель приймає рішення та підтримувати її роботу у визначених межах.

5. Валідація та порівняння з іншими методами — для визначення ефективності нейронних мереж у класифікації зображень легень важливо проводити порівняння з іншими методами діагностики, такими як традиційні методи обробки зображень чи інші машинні навчання. Це допоможе оцінити переваги та обмеження використання нейронних мереж у медичній діагностиці.

Загалом нейронні мережі для класифікації зображень легень у медицині є галуззю, яка активно розвивається. Подальші дослідження та інновації дозволять покращити точність, швидкість та пояснюваність цих систем, що відкриватиме нові можливості для ранньої діагностики та ефективного лікування захворювань легень.

**Висновки.** Розглянуто проблему класифікації зображень легень людини для медичної діагностики з використанням нейронних мереж. Проаналізовано попередні дослідження, в яких використовувалися різні архітектури нейронних мереж, такі як згорткові нейронні мережі та попередньо навчені моделі. Виявлено, що застосування нейронних мереж має великий потенціал для ефективної класифікації зображень легень у медицині.

Важливою частиною процесу вважаємо методи підготовки даних, таких як нормалізація даних, вирівнювання розмірів зображень та аугментація даних. Вказані методи забезпечують якісну інформацію для навчання нейронної мережі і покращують її ефективність.

Процес навчання нейронної мережі описаний з використанням методів оптимізації та контролю перенавчання. Валідація моделі та оцінка її ефективності проведені за допомогою розрахунку різних метрик, таких як точність, чутливість і специфічність.

Застосування нейронних мереж для класифікації зображень легень у медицині має значний потенціал. Вони можуть бути використані для автоматичного виявлення різних захворювань та сприяти покращенню діагностики та лікування. Однак для досягнення максимальних результатів необхідно провести додаткові дослідження та впровадити покращення, що сприятимуть збільшенню точності та надійності класифікації.

Загалом подано важливі відомості щодо класифікації зображень легень з використанням нейронних мереж у медицині. Запропоновані дослідження відкривають нові можливості для удосконалення медичної діагностики та лікування захворювань легень, а також стимулюють подальші дослідження та розвиток в цій галузі.

**СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ**

1. Tajbakhsh N., Shin J. Y., Gurudu S. R. Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning? *IEEE Transactions on Medical Imaging*. 2017.
2. Rajpurkar P., Irvin J., Zhu K. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. 2017.
3. Hemdan H., Shouman M., Karar M. Automatic Detection of COVID-19 from Chest X-ray Images using Deep Learning. *IEEE*. 2020.
4. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., ... & Rabinovich A. Going Deeper with Convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2015.
5. Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., ... & Berg A. C. ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*. 2015.
6. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016.
7. Pikh I., Senkivskyy V., Kudriashova A., Senkivska N. Prognostic Assessment of COVID-19 Vaccination Levels. In *International Scientific Conference «Intellectual Systems of Decision Making and Problem of Computational Intelligence»*. 2022. (pp. 246-265). Springer, Cham. ISSN 2367-4512 ISSN 2367-4520 (electronic) ISBN 978-3-031-16202-2 ISBN 978-3-031-16203-9 (eBook) doi: <https://doi.org/10.1007/978-3-031-16203-9>.

**REFERENCES**

1. Tajbakhsh, N., Shin, J. Y., & Gurudu, S. R. (2017). Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning? *IEEE Transactions on Medical Imaging* (in English).
2. Rajpurkar, P., Irvin, J., & Zhu, K. (2017). CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning (in English).
3. Hemdan, H., Shouman, M., & Karar, M. (2020). Automatic Detection of COVID-19 from Chest X-ray Images using Deep Learning. *IEEE* (in English).
4. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going Deeper with Convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (in English).
5. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Berg, A. C. (2015). ImageNet Large Scale Visual Recognition Challenge: *International Journal of Computer Vision (IJCV)* (in English).
6. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (in English).
7. Pikh, I., Senkivskyy, V., Kudriashova, A., & Senkivska, N. Prognostic Assessment of COVID-19 Vaccination Levels. In *International Scientific Conference «Intellectual Systems of Decision Making and Problem of Computational Intelligence»*. 2022. (pp. 246-265). Springer, Cham. ISSN 2367-4512 ISSN 2367-4520 (electronic) ISBN 978-3-031-16202-2 ISBN 978-3-031-16203-9 (eBook) doi: <https://doi.org/10.1007/978-3-031-16203-9> (in English).

**CLASSIFICATION OF LUNG IMAGES USING NEURAL NETWORKS**

I. V. Pikh<sup>1,2</sup>, N. M. Mykhailevych<sup>1</sup>, K. Ju. Poznukhov<sup>1</sup>

<sup>1</sup>*Ukrainian Academy of Printing,  
19, Pid Holoskom St., Lviv, 79020, Ukraine*

<sup>2</sup>*Lviv Polytechnic National University,  
12, Stepana Bandery St., Lviv, 79013, Ukraine  
pikhirena@gmail.com*

*Medical diagnostics has always been an important branch of health care. The ability to quickly and accurately determine a patient's condition is critical for providing effective medical care and treatment. In this regard, in recent decades there has been a growing interest in the use of neural networks in medicine. Neural networks show significant potential in the classification of lung images for early diagnosis of diseases and contribute to the automation of this process. The use of neural networks allows one to improve the accuracy and speed of classification, and also makes it possible to detect pathological changes in the early stages of the development of diseases. Thus, the use of neural networks in medical diagnostics can significantly improve the quality of medical services and improve treatment outcomes.*

*This article discusses the application of neural networks for the classification of lung images in medical diagnostics. Various neural network architectures, including convolutional neural networks and pre-trained models, are explored to help improve classification performance. The article provides an overview of previous research in the field of application of neural networks in medical diagnostics using images. The process of data preparation for training models, methods of validation and evaluation of their effectiveness, including the use of various metrics and cross-validation, are described. In addition, possible applications of neural networks in medicine are considered, such as early detection of lung diseases, decision support, automated screening system, and personalized medicine. Recommendations are given for further research and improvements, such as expanding datasets, improving neural network architectures, ensuring interpretability of results, and comparing with other diagnostic methods. In general, the article opens up new opportunities for improving medical diagnosis and treatment of lung diseases using neural networks.*

**Keywords:** *neural networks, image classification, medical diagnostics, deep learning, model validation, performance evaluation, performance metrics, cross-validation, error matrix, error analysis, training data preparation, data set expansion.*

*Стаття надійшла до редакції 12.02.2024.*

*Received 12.02.2024.*