

DOI: 10.35681/1560-9189.2022.24.2.274945

УДК 004.89

Є. М. Федорченко, А. О. Олійник, О. О. Степаненко,  
Т. В. Федорончак, М. О. Чорнобук, С. К. Корнієнко

Національний університет «Запорізька політехніка»  
вул. Жуковського, 64, 69063 Запоріжжя, Україна

## Гібридна згорткова мережа для обробки зображень рентгенівських знімків для виявлення захворювання COVID-19

*Проведено аналіз різних моделей машинного навчання в розрізі діагностики ураження COVID-19 за рентгенівськими знімками легень пацієнтів. У результаті було розроблено модель, яка заснована на гібридній згортковій нейронній мережі, що здатна досягти точності класифікації у 91 %. Модель може використовуватись як допоміжний інструмент діагностики для медичного персоналу, що призведе до зменшення вірогідності лікарської помилки.*

**Ключові слова:** дерева прийняття рішень, метод опорних векторів, класифікація, нейронна мережа, перцептрон.

### Вступ

За останні 3 роки людство зіштовхнулося з епідемією COVID-19, поширенням інфекційного захворювання, що викликається вірусом SARS-CoV-2. Пандемія призвела до серйозних соціально-економічних проблем по всьому світу, а також до необхідності розробки нових медичних технологій [1].

Для діагностики атипової пневмонії при COVID-19 проводиться рентгенографія легенів і комп'ютерна томографія. Аналіз знімків дає лікареві змогу оцінити ступінь ураження легень, прогнозувати можливе погіршення ситуації і розробити стратегію допомоги пацієнту [2]. Але для подібної діагностики характерний людський фактор: лікар робить помилки. Особливо це проявляється при сильному навантаженні.

Перспективною у розрізі діагностики є вже відома технологія використання моделей машинного навчання для розпізнавання образів. Так, нейромережу, що створена австралійським стартапом DetectED-X для виявлення онкологічних захворювань, використовують для діагностики COVID-19 [3].

Подібне використання інформаційних технологій дає змогу проводити діагностику швидше, точніше, що, у свою чергу, є критичним в умовах виключної навантаженості закладів охорони здоров'я.

© Є. М. Федорченко, А. О. Олійник, О. О. Степаненко,  
Т. В. Федорончак, М. О. Чорнобук, С. К. Корнієнко

Далі буде розглядатися та вирішуватися проблема розробки системи, що може діагностувати COVID-19 за рентгенівськими знімками пацієнтів, з оглядом різних алгоритмів машинного навчання: згорткових нейронних мереж, методу опорних векторів, дерев прийняття рішень, методу  $k$ -найближчих.

Зараз машинне навчання в цілому і, зокрема розпізнавання образів, отримали широке практичне застосування в багатьох сферах діяльності.

Дуже плідною є спільна робота людей і систем штучного інтелекту у сфері медицини. Зокрема, застосування машинного розпізнавання образів у радіології здатне підвищити кваліфікацію звичайного фахівця, допомагаючи йому поставити діагноз у спірних або складних ситуаціях. Навчивши нейронну мережу на величезній кількості радіологічних зображень з відомими діагнозами, можна отримати систему, яка здатна виявляти приховані патології, хвороби, що знаходяться на ранніх стадіях, або рідкісні захворювання. Застосування такої системи здатне зменшити кількість помилкових діагнозів і врятувати життя багатьох людей [4].

Для допомоги в діагностиці COVID-19 на основі рентгенівських знімків необхідно розробити модель машинного навчання, що здатна з максимальною точністю класифікувати дане зображення в три класи: відсутність захворювань, COVID-19 та інші захворювання. Поділ COVID-19 та інших захворювань на 2 різних класи є необхідним, оскільки багато інших інфекційних захворювань легенів мають подібну картинку на рентгені, що може ввести лікаря в оману [5].

## Постановка проблеми

Розпізнавання — віднесення об'єктів, що пред'являються, до певних класів за допомогою застосування відомих правил класифікації.

Необхідно розглянути різні алгоритми машинного розпізнавання образів і оцінити їх за критеріями швидкості роботи та точності класифікації. Останній критерій є ключовим, оскільки швидкість роботи алгоритму може змінюватися залежно від використаного обладнання, а точність — ні.

Проблему класифікації можна формально визначити як задачу оцінки мітки  $\gamma$  для вхідного вектора  $x$  розмірності  $K$ , де  $x \in X \subseteq R^K$  та  $\gamma \in Y = \{C_1, C_2, \dots, C_Q\}$ . Ця задача вирішується за допомогою використання правила чи функції класифікації  $g: X \rightarrow Y$ , що є здатною передбачати мітки нових векторів. Для алгоритмів керованого навчання, які й розглядаються нижче, надається тренувальний набір даних з  $N$  точок, що представлені  $D$ , з якого може бути відкориговано  $g: D = \{(x_i, y_i), i = 1, \dots, N\}$  [6].

## Мета та задачі дослідження

Об'єкт дослідження — процес виявлення ураження COVID-19 за зображеннями рентгенівських знімків легенів.

Предмет дослідження — методи розпізнавання образів, які можуть бути використаними для вирішення поставленої задачі.

Мета роботи — розробка модифікованого алгоритму машинного навчання для ефективного виявлення ураження COVID-19 за зображеннями рентгенівських знімків легенів.

Метод дослідження — відомі моделі, нейронні мережі, в тому числі згорткові нейронні мережі.

## Огляд алгоритмів машинного навчання

Дерева прийняття рішень розглядаються в статтях [7, 8]. Дерева знаходять застосування у класифікації зображень. Так, у статті [7] запропоновано класифікацію точок ландшафту на основі супутникових знімків. У [8] розглядається можливість попереднього отримання абстрактних характеристик зображень і подальшого використання дерев на оброблених даних для отримання моделі з високою точністю класифікації.

Із переваг методу можна виділити прозорість фінальної моделі, досить високі результати класифікації зображень після отримання абстрактних характеристик, а також відсутність необхідності нормалізувати вхідні дані.

До недоліків відносять необхідність істотної попередньої обробки вхідних даних і часте виникнення проблеми перенавчання моделі.

У статтях [9, 10] розглядається метод опорних векторів. Зокрема, в [9] запропоновано бінарну класифікацію зображень після простої попередньої обробки. Разом із використанням методу опорних векторів вдалося отримати досить високу точність класифікації. У [10] завдяки використанню методу опорних векторів разом зі складним алгоритмом попередньої обробки вхідних даних для класифікації зображень земельних ділянок вдалося досягти досить високої точності класифікації у 90,6 %.

Із переваг алгоритму можна виділити високі результати класифікації зображень після отримання абстрактних характеристик, можливість ефективної обробки досить великих розмірностей даних.

Необхідність істотної попередньої обробки вхідних даних і відсутність прозорості роботи моделі є основними недоліками методу опорних векторів.

Нейронні мережі, зокрема згорткові нейронні мережі, та їхні модифікації розглядаються в [11–13]. Використання так званих згорткових нейронних мереж дає змогу отримати разюче високу точність класифікації зображень. Так, запропонована у статті [11] згорткова нейронна мережа досягає точності у 75 % на наборі даних, що містить 60 тисяч зображень. У статті [13] розглядаються нейромережі, що засновані на архітектурах VGG16 та VGG19, які використовуються для класифікації рентгенівських знімків з метою діагностики пневмонії. Авторам статті вдалося досягти точності моделі у 95,7 %. У роботі [12] пропонується використання модифікованих нейромережових архітектур Xception та ResNet50V2 безпосередньо для класифікації рентгенівських знімків з підозрою на COVID-19, що дає змогу досягти точності у 91,4 %.

Перевагами нейромереж є відсутність необхідності попередньої обробки, оскільки нейронні мережі працюють з сирими даними. Окрім цього, з використанням цього методу теоретично можна досягти рівня точності, наближеного до такого рівня у людини.

Із недоліків цього методу можна виділити високі витрати обчислювальних ресурсів на навчання та роботу нейромережі, а також непрозорість моделі.

Такі методи як  $k$ -найближчих сусідів дають змогу отримати відносно великі значення точності розпізнавання, а разом з тим є прозорими. Тобто, рішення цих

моделей щодо класифікації того чи іншого об'єкта обґрунтовані за зрозумілим для людини принципом. Без сумнівів, це може бути важливим фактором у виборі методу аналізу знімків легенів, оскільки дасть змогу радіологу самому зрозуміти ключові критерії для діагностики COVID-19 і перевірити роботу алгоритму, маючи опірні дані.

З іншого боку, зазначені вище алгоритми, а також метод опорних векторів вимагають попередньої обробки даних. Така обробка буде витратити додаткові обчислювальні ресурси, а для її реалізації необхідно буде провести широку дослідницьку роботу або навіть розробити ще одну модель машинного навчання.

Окрім цього, нейронні мережі потенційно мають змогу розпізнати більш глибокі закономірності у вхідних даних і досягти більш високої точності класифікації зображень легенів пацієнтів. На це вказують описані вище успішні результати обробки великих об'ємів вхідних даних за допомогою згортової нейромережі.

Звичайно, нейронні мережі мають значний недолік — вони програють усім розглянутим алгоритмам у швидкості роботи. Як показано в статті, в якій розглядається ефективність і швидкість різних алгоритмів машинного навчання у задачі класифікації, згортові нейронні мережі можуть потребувати у сотні разів більше часу, ніж алгоритм  $k$ -найближчих на одному тренувальному наборі [14].

З огляду на всі фактори можна зробити висновок, що саме нейронні мережі є найкращим вибором як модель машинного навчання для діагностики COVID-19 на базі класифікації зображень знімків легенів пацієнтів. Підсумковий аналіз розглянутих алгоритмів надано в табл. 1 [15–35].

Таблиця 1. Аналіз розглянутих алгоритмів

Назва методу	Можливість ефективно обробляти сирі дані	Прозорість принципу класифікації	Необхідність витрати значних ресурсів на навчання моделі	Необхідність витрати значних ресурсів на роботу моделі	Схильність до перенавчання [15]	Час на обробку даних з еталонного набору [14], с
$K$ -найближчих	Ні	Так	Ні	Так	Висока	0,009
Дерева прийняття рішень	Ні	Так	Так	Ні	Висока	0,07
Метод опорних векторів	Ні	Ні	Так	Ні	Низька	18,12
Нейронні мережі	Так	Ні	Так	Так	Низька	33,5

З огляду на зазначені вище характеристики різних алгоритмів машинного навчання, а також на результати їхнього тестування, що наведені нижче, виникає не-

обхідність використання моделі, яка відрізняється від стандартних. Як буде показано далі, модифікована згорткова нейронна мережа може досягти точності розпізнавання, значно більшої за точність відомих алгоритмів у даній задачі [18].

## **Розробка моделі машинного навчання**

Для навчання та тестування всіх алгоритмів були використані дані з відкритого джерела [16]. Зображення були стиснуті до розміру 200 на 200 пікселів для економії ресурсів, зокрема пам'яті та часу процесора. Це дало можливість навчати моделі з використанням значно більших наборів даних.

Для тестування моделей були сформовані два набори вхідних зображень: менший, у складі якого 300 зображень для навчання, 150 для тестування та більший, у складі якого 1200 зображень для навчання, 300 зображень для тестування.

Для створення моделей на базі методу опорних векторів, дерев прийняття рішень і простих нейронних мереж була використана бібліотека Accord.NET.

Оскільки жодна із моделей вище не може ефективно працювати з сирими даними зображень, для витягання з необроблених даних вектора ознак фіксованої довжини був використаний алгоритм Bag of visual words (набір візуальних слів) з Accord.NET. У рамках цього алгоритму безпосередньо для витягання ознак використовувався метод локальних бінарних шаблонів, а для зменшення розмірності вектору ознак — бінарне розщеплення або кластеризація методом  $k$ -середніх.

У розрізі розробки згорткової нейронної мережі гостро постала проблема перенавчання, що проявляється у вигляді зменшення точності моделі на деяких епохах, а також у вигляді неможливості досягнення вищих рівнів точності моделі. Існує декілька різних шляхів вирішення цих проблем.

По-перше, зміна архітектури нейронної мережі на більш відповідну до конкретної задачі дасть змогу запобігти перенавчанню та досягти більш точних результатів у класифікації. З одного боку, збільшення кількості шарів і нейронів на кожному шарі дасть нейромережі змогу виявити більш глибокі закономірності між вхідними даними та результатами. З іншого боку, подальше збільшення складності мережі може привести і до посилення ефекту перенавчання. Часто буває, що саме зменшення кількості шарів дозволяє мережі краще узагальнювати вхідні дані. У будь-якому разі лише за допомогою практичної перевірки можна встановити найбільш ефективну конфігурацію мережі.

По-друге, можна використовувати більший набір тренувальних даних для навчання моделі. Зазвичай це допомагає зменшити перенавчання. Однак, збільшення тренувального набору дасть позитивні результати тільки, якщо вхідні дані є достатньо різноманітними. Разом із цим збільшення кількості даних, що будуть оброблені, пропорційно збільшить витрати обчислювальних ресурсів системи [17–25].

Найкращі результати тестування кожного із відомих методів наведено на рис. 1. Можна бачити, що жоден із методів не зміг досягти точності, яка є більшою за 85 %.




Рис. 1. Результати роботи відомих методів

## Розробка моделі на основі згорткової нейронної мережі

Для створення більш складної, багатошарової згорткової нейронної мережі було використано бібліотеку Keras для мови Python, яка є надбудовою над іншою бібліотекою — TensorFlow.

Було розроблено згорткову нейромережу, конфігурацію якої наведено в табл. 2, а також на рис. 2. Вона складається з 8 шарів, причому лише 4 з них мають параметри, що підлягають навчанню. Нейромережі невеликого розміру з подібною архітектурою зазвичай використовуються для класифікації простих наборів зображень (зокрема, рукописних цифр) на декілька класів. Умовно назвемо цю модифікацію «Проста».

Таблиця 2. Конфігурація першої «Простої» модифікації згорткової нейронної мережі

Тип шару	Вихідна форма	Кількість параметрів
Rescaling	(None, 299, 299, 3)	0
Згортковий шар з 8 фільтрів 3×3	(None, 299, 299, 8)	224
Агрегувальний шар	(None, 149, 149, 8)	0
Згортковий шар з 16 фільтрів 3×3	(None, 149, 149, 16)	1168
Агрегувальний шар	(None, 74, 74, 16)	0
Flatten	(None, 87616)	0
Повноз'єднаний шар розміром 64 нейрони	(None, 64)	5607488
Повноз'єднаний шар розміром 3 нейрони	(None, 3)	195

Як функція активації використовується функція ReLU:  $f(x) = \max(0, x)$ .

Для оцінки точності моделі використовується категоріальна функція перехресної ентропії (categorical cross entropy function). Як міра точності використана частота збігу передбаченого моделлю значення з істинним.

Зовнішній шар зміни масштабу (rescaling) приймає на вхід сирі дані зображення та переводить значення насиченості кожного пікселя у діапазон від 0 до 1.

Три вихідних нейрони відповідають імовірності належності зображення, що розглядається, одному з трьох класів: ураження COVID-19, нормальний стан легенів, інші захворювання.

У результаті тестування перша модифікація «Проста» змогла досягти точності класифікації у 75,17 % для меншого та 84,33 % для більшого наборів.




Рис. 2. Графічне зображення структури першої «Простої» модифікації згорткової нейронної мережі

Як можна бачити з результатів тестування, архітектура «Простої» модифікації недостатньо складна, тому мережа не здатна знайти достатньо глибокі зв'язки вхідних даних з вихідними та досягти точності класифікації хоча б у 85 % на більшому наборі даних. Вочевидь, необхідно збільшити розміри нейронної мережі.

Було розроблено другу, більш складну модифіковану згорткову нейромережу. Умовно назвемо її «Ускладнена» модифікації. Її структуру наведено в табл. 3, а також на рис. 3. У рамках другої модифікації було видалено згортковий шар з 8 фільтрів 3×3 та наступний за ним агрегувальний шар. Було також додано згортковий шар із 32 фільтрів 3×3, згортковий шар із 64 фільтрів 3×3 та два агрегувальні шари, що йдуть за ними. Нарешті, додано дропаут-шар з вірогідністю виключення 0,1. Повно'єднаний шар розміром 64 нейрони збільшено до 128 нейронів.

Таблиця 3. Конфігурація другої «Ускладненої» модифікації згорткової нейронної мережі

Тип шару	Вихідна форма	Кількість параметрів	Коментар
Rescaling	(None, 299, 299, 3)	0	
Згортковий шар із 8 фільтрів 3×3	(None, 299, 299, 8)	224	Шар видалено
Агрегувальний шар	(None, 149, 149, 8)	0	Шар видалено
Згортковий шар із 16 фільтрів 3×3	(None, 299, 299, 16)	448	
Агрегувальний шар	(None, 149, 149, 16)	0	
Згортковий шар із 32 фільтрів 3×3	(None, 149, 149, 32)	4640	Шар додано

Тип шару	Вихідна форма	Кількість параметрів	Коментар
Агрегувальний шар	(None, 74, 74, 32)	0	Шар додано
Згортковий шар із 64 фільтрів 3×3	(None, 74, 74, 64)	18496	Шар додано
Агрегувальний шар	(None, 37, 37, 64)	0	Шар додано
Дропаут шар з вірогідністю виключення 0,1	(None, 37, 37, 64)	0	Шар додано
Flatten	(None, 87616)	0	
Повноз'єднаний шар розміром 128 нейронів	(None, 128)	11214976	Кількість нейронів у шарі збільшено до 128
Повноз'єднаний шар розміром 3 нейрони	(None, 3)	387	

У результаті тестування друга модифікація «Ускладнена» змогла досягти точності класифікації у 79,19 % для меншого та 85,67 % для більшого наборів.




Рис. 3. Графічне зображення структури другої «Ускладненої» модифікації згорткової нейронної мережі

Для зменшення ефекту перенавчання та загальної оптимізації до нейронної мережі були зроблені деякі зміни.

Рентгенівські зображення тепер розглядаються як двовимірний масив дійсних чисел, а не векторів з трьома значеннями. Рентгенівські знімки за своєю природою є монохромними, тому немає потреби в обробці кожного з каналів окремо. Використовується лише алгоритм навчання Adam, швидкість навчання зменшено вдвічі. Це допоможе зменшити ефект перенавчання.

Внесено деякі зміни до структури мережі. В усіх згорткових шарах розміри фільтрів змінено з 3×3 на 8×8, а також додано згортковий шар із 8 фільтрів 8×8, згортковий шар зі 128 фільтрів 8×8 і 2 агрегувальних шари, що йдуть за ними. Окрім цього, один повноз'єднаний шар розміром 128 нейронів замінено трьома послідовними повноз'єднаними шарами розміром 2048 нейронів

Конфігурацію третьої модифікації наведено у табл. 4. Умовно назвемо її «Складна». Окрім цього, графічне зображення конфігурації мережі наведено на рис. 4.



Таблиця 4. Конфігурація третьої «Складної» модифікації згорткової нейронної мережі

Тип шару	Вихідна форма	Кількість параметрів	Коментар
Rescaling	(None, 299, 299, 1)	0	
Згортковий шар із 8 фільтрів 8×8	(None, 299, 299, 8)	520	Шар додано
Агрегувальний шар	(None, 149, 149, 8)	0	Шар додано
Згортковий шар із 16 фільтрів 8×8	(None, 149, 149, 16)	8208	Розмір фільтра змінено на 8×8
Агрегувальний шар	(None, 74, 74, 16)	0	
Згортковий шар із 32 фільтрів 8×8	(None, 74, 74, 32)	32800	Розмір фільтра змінено на 8×8
Агрегувальний шар	(None, 37, 37, 32)	0	
Згортковий шар із 64 фільтрів 8×8	(None, 37, 37, 64)	131136	Розмір фільтра змінено на 8×8
Агрегувальний шар	(None, 18, 18, 64)	0	
Згортковий шар зі 128 фільтрів 8×8	(None, 18, 18, 128)	524416	Розмір фільтра змінено на 8×8
Агрегувальний шар	(None, 9, 9, 128)	0	
Дропаут шар з вірогідністю виключення 0,1	(None, 9, 9, 128)	0	
Flatten	(None, 10368)	0	
Повноз'єднаний шар розміром 128 нейронів	(None, 128)	11214976	Шар видалено
Повноз'єднаний шар розміром 2048 нейронів	(None, 2048)	21235712	Шар додано
Повноз'єднаний шар розміром 2048 нейронів	(None, 2048)	4196352	Шар додано
Повноз'єднаний шар розміром 2048 нейронів	(None, 2048)	4196352	Шар додано
Повноз'єднаний шар розміром 3 нейрони	(None, 3)	6147	

У результаті тестування, яке наведено за епохами навчання у табл. 5, третя модифікація «Складна» змогла досягти точності класифікації у 68,46 % для меншого та 87,33 % для більшого наборів.

Таблиця 5. Результати тестування третьої «Складної» модифікації згорткової нейронної мережі

№ Епохи (ітерації)	Результати на наборі даних з 320 екземплярів		Результати на наборі даних з 1220 екземплярів	
	Помилка	Точність	Помилка	Точність
1	1,0984	0,3691	0,8019	0,5600
2	1,0910	0,3691	0,6864	0,5667
3	1,0710	0,3691	0,6345	0,6833
4	1,0493	0,5302	0,5606	0,7733
5	0,9629	0,5436	0,4671	0,8233
6	0,9083	0,6443	0,3948	0,8500
7	0,8218	0,6711	0,4411	0,8367
8	0,8826	0,6846	0,3411	0,8733




Рис. 4. Графічне зображення структури третьої «Складної» модифікації згорткової нейронної мережі

Подібне невелике зростання точності на більшому наборі та фактично відсутнє — на меншому, при значному збільшенні складності нейромережі може свідчити про те, що для подолання перенавчання та досягнення точності, що прагне до 90 % і більше, потрібний набагато більший об'єм вхідних даних.

Для перевірки гіпотези навчимо «Складну» мережу на масиві даних розміром 10500 рентгенівських знімків (по 3500 знімків на кожен клас), отриманих із того ж джерела, що й попередні набори даних. 20 % знімків використаємо для валідації. Результати тестування за епохами навчання наведено у табл. 6.

У результаті останнього тестування мережа досягла точності у 91,19 %, що доводить висловлене раніше припущення.

Таблиця 6. Результати тестування «Складної» модифікації на 10500 знімках

№ Епохи (ітерації)	Результати на наборі даних з 10500 екземплярів	
	Помилка	Точність
1	0,5535	0,7762
2	0,3596	0,8571
3	0,3448	0,8719
4	0,2907	0,8871
5	0,2786	0,8952
6	0,3052	0,8867
7	0,3119	0,8857
8	0,2688	0,9119

## Результати

На рис. 5 наведено підсумкове порівняння ефективності різних моделей машинного навчання на двох наборах даних. Та хоча згорткова нейронна мережа лише на кілька відсотків випереджає метод опорних векторів, ця модель має набагато більший потенціал, який проявляється при подальшому збільшенні тренувальних наборів, як було продемонстровано вище.

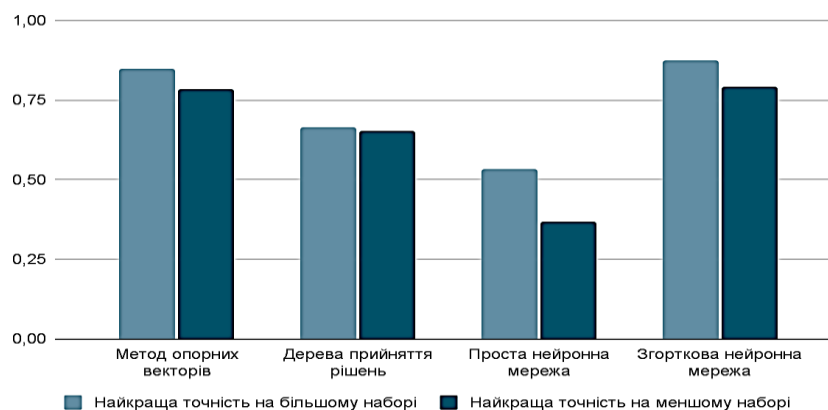


Рис. 5. Результати роботи різних методів

## Висновки

Під час виконання роботи проаналізовано класичні методи машинного навчання: дерева прийняття рішень, метод опорних векторів, а також прості нейромережі. Однак, набагато кращі результати та більший потенціал у вирішенні поставленої задачі показали моделі, що засновані на згорткових нейронних мережах.

Отримано наступні результати точності для трьох модифікованих архітектур нейронних мереж («Простої», «Ускладненої» і «Складної») на масиві навчальних

даних з 1500 зображень: 84,33 %, 85,67 % та 87,33 % відповідно. Результати «Складної» модифікації нейронної мережі є найкращими серед усіх розглянутих моделей.

Також було з'ясовано, що «Складна» модель має потенціал для збільшення точності. Це продемонстровано при навчанні «Складної» модифікованої мережі на вхідних даних із 10500 зображень, коли модель досягла точності у 91,19 %.

1. Global Economic Effects of COVID-19: Overview. URL: <https://sgp.fas.org/crs/row/R46270.pdf>
2. E. Martínez Chamorro, A. Díez Tascón, L. Ibáñez Sanz, S. Ossaba Vélez, S. Borrueal Nacenta. Radiologic diagnosis of patients with COVID-19. *Radiología* (English Edition). Jan. – Feb. 2021. Vol. 63. Issue 1. P. 56–73
3. DetectED-X. detectedx.com, 2022. URL: <https://detectedx.com/about/>
4. Garry Choy, Omid Khalilzadeh, Mark Michalski, Synho Do, Anthony E. Samir, Oleg S. Pianykh, J. Raymond Geis, Pari V. Pandharipande, James A. Brink, Keith J. Dreyer. Current Applications and Future Impact of Machine Learning in Radiology. *Radiology*. Vol. 288, No. 2
5. Islam N., Ebrahimzadeh S., Salameh J-P, Kazi S, Fabiano N., Treanor L., Absi M., Hallgrimson Z, Leeflang M.M.G, Hooft L., Van der Pol C.B., Prager R., Hare S.S., Dennie C., Spijker R., Deeks J.J, Dinnes J., Jenniskens K., Korevaar D.A., Cohen J.F., Van den Bruel A., Takwoingi Y., van de Wijert J, Damen JAAG, Wang J., McInnes M.D.F. Thoracic imaging tests for the diagnosis of COVID-19. *Cochrane Database of Systematic Reviews*. 2021. Issue 3. Art. No.: CD013639.
6. Pérez-Ortiz M., Jiménez-Fernández S., Gutiérrez P., Alexandre E., Hervás-Martínez C., and Salcedo-Sanz S. A Review of Classification Problems and Algorithms in Renewable Energy Applications. *Energies*. Aug. 2016. Vol. 9, No. 8. H. 607.
7. João Otavio Firigato. Decision Tree for Satellite Image Classification. [www.linkedin.com](http://www.linkedin.com), 2019. URL: <https://www.linkedin.com/pulse/decision-tree-satellite-image-classification-joão-otavio>
8. Pavel Surynek, Ivana Luksová. Automated Classification of Bitmap Images using Decision Trees. *Polibits*. 2011. Vol. 44. P. 11–18. doi: 10.17562/PB-44-2.
9. Sharon Morris. Image Classification Using SVM. [rpubs.com](http://rpubs.com), 2018. URL: [https://rpubs.com/Sharon\\_1684/454441](https://rpubs.com/Sharon_1684/454441)
10. Angelos Tzotsos, Demetre Argialas. Support Vector Machine Classification for Object-Based Image Analysis. In: Blaschke, T., Lang, S., Hay, G.J. (eds) Object-Based Image Analysis. Lecture Notes in Geoinformation and Cartography. Springer, Berlin, Heidelberg (2008). P. 663–677 doi: 10.1007/978-3-540-77058-9\_36.
11. Akwasi D Akwaboah. Convolutional Neural Network for CIFAR-10 Dataset Image Classification. [www.researchgate.net](http://www.researchgate.net), 2019. URL: [https://www.researchgate.net/publication/337240963\\_Convolutional\\_Neural\\_Network\\_for\\_CIFAR-10\\_Dataset\\_Image\\_Classification](https://www.researchgate.net/publication/337240963_Convolutional_Neural_Network_for_CIFAR-10_Dataset_Image_Classification)
12. Rahimzadeh M., and Attar A. A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in Medicine Unlocked*. 2020. Vol. 19. 100360. ISSN 2352-9148.
13. Wahyudi Setiawan and Fitri Damayanti. Layers Modification of Convolutional Neural Network for Pneumonia Detection. 2020. *J. Phys.: Conf. Ser.* 1477 052055.
14. Vakili Meysam & Ghamsari Mohammad & Rezaei, Masoumeh. Performance Analysis and Comparison of Machine and Deep Learning Algorithms for IoT Data Classification. Unpublished.
15. Shahadat Uddin, Arif Khan, Md Ekramul Hossain, Mohammad Ali. Comparing different supervised machine learning algorithms for disease prediction. *BMC Med Inform Decis Mak* 19, 281, 2019
16. COVID-19 Radiography Database, [www.kaggle.com](http://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database), 2022. URL: <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>
17. Yin, Xue. An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*. 1168. 022022. 10.1088/1742-6596/1168/2/022022.
18. Oliinyk A., Fedorchenko I., Stepanenko A., Katschan A., Fedorchenko Y., Kharchenko A., Goncharenko D. Development of genetic methods for predicting the incidence of volumes of pollutant emissions in air. In: 2nd International Workshop on Informatics and Data-Driven Medicine, CEUR Workshop Proceedings, 2019. P. 340–353. ISSN: 16130073.

19. Fedorchenko I., Oliinyk A., Stepanenko A., Zaiko T., Korniienko S., Burtsev N. Development of a genetic algorithm for placing power supply sources in a distributed electric network. *Eastern-European Journal of Enterprise Technologies*. 2019. **5**. P. 6–16. doi: 10.15587 / 1729-4061.2019.180897.
20. Fedorchenko I., Oliinyk A., Stepanenko A., Zaiko T., Shylo S., Svyrydenko A. Development of the modified methods to train a neural network to solve the task on recognition of road users, *Eastern-European Journal of Enterprise Technologies*. 2019. **2**. P. 46–55. doi: 10.15587/1729-4061.2019.164789.
21. Oliinyk A., Fedorchenko I., Stepanenko A., Rud M., Goncharenko D. Implementation of Evolutionary Methods of Solving the Travelling Salesman Problem in a Robotic Warehouse. *Lecture Notes on Data Engineering and Communications Technologies*. 2021. **48**. P. 263–292. doi: 10.1007/978-3-030-43070-2\_13.
22. Tkachenko R., Izonin I., Greguš ml. M., Tkachenko P., and Dronyuk I. Committee of the SGTm Neural-Like Structures with Extended Inputs for Predictive Analytics in Insurance. *Communications in Computer and Information Science*. 2019. **1054**. P. 121–132. doi: 10.1007/978-3-030-27355-2\_9.
23. Fedorchenko I., Oliinyk A., Stepanenko O., Zaiko T., Svyrydenko A., Goncharenko D. Genetic method of image processing for motor vehicle recognition. 2nd International Workshop on Computer Modeling and Intelligent Systems, CMIS 2019; CEUR Workshop Proceedings. Zaporizhzhia; Ukraine; 15 April 2019 – 19 April 2019. Vol. 2353. P. 211–226. ISSN: 16130073
24. L. S.K., S. Mohanty, S. K., A. N., G. Ramirez. Optimal deep learning model for classification of lung cancer on CT images. *Future Generation Computer Systems*. 2019. **92**. P. 374–382. doi: 10.1016/j.future.2018.10.009.
25. Gupta N., Gupta D., Khanna A., Rebouças Filho P., de Albuquerque V. Evolutionary algorithms for automatic lung disease detection, *Measurement*. 2019. **140**. P. 590–608. doi: 10.1016/j.measurement.2019.02.042.
26. Alsayaydeh J.A., Nj M., Syed S.N., Yoon A.W., Indra W.A., Shkarupylo V., and Pellipus C. Homes appliances control using bluetooth. *ARPJ Journal of Engineering and Applied Sciences*, 2019. Vol. 14(19). P. 3344–3357.
27. Abiyev R., Ma'aitah M. Deep Convolutional Neural Networks for Chest Diseases Detection. *Journal of Healthcare Engineering*. 2018 (2018). P. 1–11. doi: 10.1155/2018/4168538.
28. Alsayaydeh J.A.J., Aziz A., Rahman A.I.A., Abbasi M.I., Khang A.W.Y. Development of Programmable Home Security using GSM System for Early Prevention. *ARPJ Journal of Engineering and Applied Sciences*. 2021. Vol. 16(1). P. 88–97.
29. Alsayaydeh J.A.J., Khang W.A.Y., Indra W.A., Puspanathan J.B., Shkarupylo V., Zakir Hos-sain A.K.M., and Saravanan S. Development of vehicle door security using smart tag and fingerprint system. *ARPJ Journal of Engineering and Applied Sciences*. 2019. Vol. 9(1). P. 3108–3114.
30. Ke Q., et al. A neuro-heuristic approach for recognition of lung diseases from X-ray images. *Expert Systems with Applications*. 2019. **126**. P. 218–232. doi: 10.1016/j.eswa.2019.01.060.
31. Souza J., Bandeira Diniz J., Ferreira J., França da Silva G., Correa Silva A., de Paiva A. An automatic method for lung segmentation and reconstruction in chest X-ray using deep neural networks. *Computer Methods and Programs in Biomedicine*. 2019. **177**. P. 285–296. doi: 10.1016/j.cmpb.2019.06.005.
32. C. Qin, D. Yao, Y. Shi, Z. Song, Computer-aided detection in chest radiography based on artificial intelligence: a survey, *BioMedical Engineering OnLine* 17 (2018). doi: 10.1186/s12938-018-0544-y.
33. Alsayaydeh J.A.J., Khang W.A.Y., Indra W.A., Shkarupylo V., and Jayasundar J. Development of smart dustbin by using apps. *ARPJ Journal of Engineering and Applied Sciences*. 2019. Vol. 14(21). P. 3703–3711.
34. Alsayaydeh J.A.J., Indra W.A., Khang W.A.Y., Shkarupylo V. and Jkatisan D.A.P.P. Development of vehicle ignition using fingerprint. *ARPJ Journal of Engineering and Applied Sciences*. 2019. Vol. 14(23). P. 4045–4053.
35. Jain R., Nagrath P., Kataria G., Kaushik V. Sirish, Jude D. Hemanth: Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*. 2020. **165**. 108046. doi: 10.1016/j.measurement.2020.108046.

Надійшла до редакції 09.09.2022