

УДК 004.89

DOI <https://doi.org/10.32782/tnv-tech.2025.1.13>

РОЗПІЗНАВАННЯ ВІРУСНИХ ЗАХВОРЮВАНЬ ТА НОВОУТВОРЕНЬ ШКІРИ ЗА ДОПОМОГОЮ ЗГОРТКОВИХ НЕЙРОМЕРЕЖ

Парфененко Ю. В. – кандидат технічних наук, доцент кафедри
інформаційних технологій Сумського державного університету
ORCID ID: 0000-0003-4377-5132

Кіншаков Е. В. – аспірант кафедри інформаційних технологій
Сумського державного університету
ORCID ID: 0000-0001-7116-7244

Дослідження присвячене використанню згорткових нейронних мереж для автоматизованого розпізнавання шкірних захворювань, зосереджуючись на двох основних класах – новоутвореннях шкіри та вірусні захворювання. Кожен із цих класів містить велику кількість підкласів із різною етіологією та клінічними проявами, що створює складнощі для їх точної диференціації навіть серед фахівців. Метою роботи є не лише класифікація основних груп захворювань, а й аналіз підкласів для підвищення точності діагностичних алгоритмів.

Для навчання нейромережі використано DermNet – один із найбільших відкритих датасетів з дерматологічними зображеннями, який містить широкий спектр шкірних патологій. Початковий набір даних було розподілено на навчальну та тестову вибірки, а також доповнено додатковими зображеннями із загальнодоступних джерел. Це дозволило моделі враховувати варіативність шкірних покривів, а також відмінності у відтінках, текстурі та особливостях уражень, що є критичним фактором у діагностиці.

Модель базується на глибинному навчанні із використанням класичних згорткових шарів та додаткових методів нормалізації. Вона здатна аналізувати та класифікувати захворювання на основі зображень із високою точністю. Фінальні результати показали точність (accuracy) 91%, повноту (recall) 89% та F1-міру 90%, що суттєво перевищує попередні результати, які коливалися у межах 0.7–0.75. Це доводить, що застосування вдосконалених алгоритмів та адаптивного навчання значно покращує можливості автоматизованої діагностики.

На відміну від попередніх підходів, де використовувалися базові згорткові моделі з мінімальним коригуванням гіперпараметрів, у цьому дослідженні вдалося створити більш гнучку систему, яка не лише класифікує зображення за основними класами, а й враховує відмінності між підтипами захворювань. Це особливо важливо для розмежування подібних патологій, наприклад, між доброякісними новоутвореннями та злоякісними формами або між різними типами вірусних інфекцій.

Перспективним напрямом подальших досліджень є створення ієрархічної нейромережевої системи, яка дозволить моделі спочатку визначати загальний клас патології, а потім деталізувати підтипи всередині кожної категорії. Такий підхід дасть змогу не лише підвищити точність діагностики, а й створити систему рекомендацій для медичних фахівців щодо подальшого обстеження пацієнтів. Також планується розширення набору даних для тестування моделі на інших типах шкірних захворювань, включаючи рідкісні форми патологій.

Ключові слова: згорткова нейронна мережа, класифікація, детектування об'єктів, класифікація зображень, машинне навчання, система прийняття рішень, інтелектуальна технологія, оптимізація, сегментація.

Parfenenko Yu. V., Kinshakov E. V. Recognition of viral diseases and skin neoplasms using convolutional neural networks

This study focuses on the use of convolutional neural networks for the automated recognition of skin diseases, specifically targeting two main classes: skin neoplasms and viral diseases. Each of these classes contains a large number of subclasses with different etiologies and clinical

manifestations, making their accurate differentiation challenging even for specialists. The goal of this research is not only to classify the main disease groups but also to analyze their subclasses to improve the accuracy of diagnostic algorithms.

The neural network was trained using DermNet, one of the largest open dermatology image datasets, which contains a wide range of skin pathologies. The initial dataset was divided into training and test sets and supplemented with additional images from publicly available sources. This approach allowed the model to account for the variability in skin types, as well as differences in tone, texture, and lesion characteristics, which are critical factors in diagnosis.

The model is based on deep learning, utilizing classical convolutional layers and additional normalization methods. It is capable of analyzing and classifying diseases from images with high accuracy. Final results showed an accuracy of 91%, a recall of 89%, and an F1-score of 90%, significantly surpassing previous results, which ranged between 0.7 and 0.75. This demonstrates that the application of advanced algorithms and adaptive training significantly enhances the capabilities of automated diagnostics.

Unlike previous approaches that relied on basic convolutional models with minimal hyperparameter adjustments, this study has developed a more flexible system that not only classifies images by primary disease categories but also considers differences between disease subtypes. This is particularly important for distinguishing similar pathologies, such as benign and malignant neoplasms or different types of viral infections.

A promising direction for future research is the development of a hierarchical neural network system, which will allow the model to first determine the general disease class and then further refine its classification into subtypes within each category. This approach will not only increase diagnostic accuracy but also provide a recommendation system for medical professionals regarding further patient examination. Additionally, there are plans to expand the dataset to test the model on other types of skin diseases, including rare pathological forms.

Keywords: convolutional neural network, classification, object detection, image classification, machine training, decision-making system, intelligent technology, optimisation, segmentation.

Вступ. Діагностика шкірних захворювань традиційно базується на візуальному огляді лікаря-дерматолога, що потребує досвіду та високої кваліфікації. Однак сучасні реалії диктують нові виклики для системи охорони здоров'я, зокрема, обмежений доступ до медичних послуг у деяких регіонах через складну соціальну та гуманітарну ситуацію. Це актуалізує потребу у віддалених інформаційних системах, які дозволяють попередньо аналізувати зображення шкіри, отримувати рекомендації та, за необхідності, звертатися до лікаря. Такий підхід сприяє своєчасному виявленню потенційно небезпечних патологій, знижує навантаження на медичних спеціалістів та покращує доступ до первинної діагностики, особливо для тих, хто тимчасово позбавлений можливості відвідувати лікарів особисто.

Однією з основних проблем у цій сфері є класифікація новоутворень шкіри та вірусних захворювань, які мають багато підтипів із різними проявами. Візуальна схожість окремих патологій значно ускладнює точне розмежування, особливо на ранніх стадіях розвитку хвороби. Це створює необхідність застосування інтелектуальних систем, які здатні аналізувати великі обсяги даних та ідентифікувати захворювання з високим рівнем достовірності.

Згорткові нейронні мережі демонструють значний потенціал у розпізнаванні складних шкірних патологій. Вони навчаються на великих наборах зображень, виявляють приховані закономірності та автоматизують процес діагностики. Їх використання дозволяє прискорити обробку даних, мінімізувати вплив людського фактора та підвищити ефективність аналізу.

У цьому дослідженні представлено підхід до розпізнавання шкірних захворювань за допомогою сучасних нейромережових алгоритмів. Навчання моделі здійснювалося на базі датасету DermNet, що є одним із наймасштабніших відкритих джерел дерматологічних зображень. Для підвищення якості класифікації передбачено побудову ієрархічної структури нейромереж, яка дозволяє деталізувати аналіз і вдосконалити точність розмежування між різними патологіями.

Отримані результати можуть стати основою для подальшої інтеграції штучного інтелекту в медичну практику, що сприятиме покращенню методів діагностики та розробці автоматизованих систем раннього виявлення шкірних захворювань.

Постановка проблеми. Автоматизоване розпізнавання шкірних захворювань залишається актуальним викликом для сучасної медицини. Традиційні методи діагностики вимагають фізичної присутності пацієнта та високої кваліфікації лікаря, що ускладнює своєчасне виявлення патологій, особливо в умовах обмеженого доступу до медичних послуг.

Складність проблеми полягає у точному розмежуванні новоутворень шкіри та вірусних захворювань, які мають широкий спектр підтипів та схожі клінічні прояви. Наявні нейромережеві моделі демонструють високі показники точності, проте їх використання обмежене відсутністю пояснюваності рішень і недостатньою деталізацією класифікації.

Предметом дослідження є розробка нейромережевої системи, яка дозволить не лише визначати загальні класи захворювань, а й розпізнавати їхні підтипи, підвищуючи рівень точності та довіри до автоматизованої діагностики. Це відкриває можливість для побудови більш гнучкої та інтерпретованої системи, яка зможе ефективно застосовуватися у клінічній практиці.

Аналіз останніх досліджень і публікацій. Використання згорткових нейронних мереж (CNN) для автоматизованої діагностики шкірних захворювань є предметом активних досліджень у сфері медичної інформатики та штучного інтелекту. Розглянемо праці, які охоплюють питання застосування CNN у класифікації шкірних патологій та перспективи їх удосконалення.

Стаття [1] присвячена проблемі автоматизованого розпізнавання шкірних захворювань, що є складним завданням через низький контраст та схожість симптомів. Автори пропонують використання згорткових нейронних мереж (CNN), зокрема MobileNet та Xception, із застосуванням transfer learning, що дозволяє підвищити точність класифікації.

Результати дослідження демонструють, що MobileNet досяг 96% точності, а Xception – 97%, перевершуючи інші популярні архітектури CNN, такі як ResNet50, InceptionV3 та DenseNet. Також розроблено веб-додаток для реального часу розпізнавання захворювань, що розширює можливості автоматизованої діагностики та її доступність.

Але у роботі розглядається обмежена кількість класів захворювань, що може впливати на узагальненість моделі [1]. Крім того, відсутня деталізація внутрішньої класифікації патологій за підтипами, що є важливим для покращення точності діагностики.

У статті [2] автори аналізують застосування згорткових нейронних мереж (CNN) для класифікації шкірних захворювань обличчя на основі клінічних зображень. Використано датасет Xiangya-Derm, що містить 2656 зображень шести типів патологій (зокрема BCC, SCC, SK, AK, ROS, LE). Було протестовано п'ять популярних архітектур CNN, а також проведено transfer learning на незалежному наборі даних.

Результати показали, що найкраща модель досягла 92.9% recall для LE, 89.2% для BCC і 84.3% для SK, а середні показники точності становили 77.0% recall і 70.8% precision.

У дослідженні [3] розглядається проблема поширення шкірних захворювань у світі, зосереджуючи увагу на Індонезії. Автори зазначають, що шкірні патології становлять 1.79% від усіх глобальних захворювань та є четвертою провідною

причиною нефатальних хвороб. Основні фактори поширення в Індонезії пов'язані з недостатнім доступом до медичних послуг, низьким рівнем гігієни та високою щільністю населення.

Використано 1203 зображення шкірних захворювань, серед яких герпес, псоріаз, короста, вітіліго тощо. Для підвищення точності моделі застосовано балансування даних, k-fold cross-validation та ансамблевий метод. Результати показали, що Grayscale-модель досягла 93% точності, тоді як RGB – 86%.

Автор [4] розглядає проблему пізньої діагностики раку шкіри, зокрема меланоми, яка є однією з найнебезпечніших форм шкірних захворювань. Автори наголошують, що традиційні методи діагностики, які застосовуються лікарями-дерматологами, є трудомісткими та займають багато часу, що може затримувати виявлення критичних патологій.

Для автоматизації процесу запропоновано глибоку згорткову нейронну мережу (CNN), навчену на 2102 дерматоскопічних зображеннях пігментованих уражень. Модель досягла 89.45% точності у класифікації раку шкіри, що свідчить про її ефективність.

У роботі [5] аналізується застосування CNN для автоматизованої класифікації шкірних уражень. Модель навчена на 129,450 клінічних зображеннях, що охоплюють 2,032 захворювання, і демонструє точність, співставну з досвідченими дерматологами.

Перевірено два завдання: ідентифікація меланоми проти доброякісних невусів та відокремлення кератиноцитарних карцином від себорейного кератозу. Отримані результати підтверджують ефективність CNN та можливість інтеграції в мобільні додатки для доступної діагностики.

У статті [6] авторами продемонстровано використання CNN для класифікації шкірних захворювань на основі термоскопічних зображень, що відображають розподіл теплових патернів на шкірі. Використано велику вибірку зображень для навчання моделі, що дозволило досягти 90% точності на валідаційних даних та 95% при класифікації.

Запропонована система може допомагати дерматологам, лікарям первинної ланки та самим пацієнтам у діагностиці шкірних захворювань. Однак дослідження зосереджене лише на термоскопічних зображеннях, тоді як у моєму дослідженні використовується ширший спектр дерматологічних даних та ієрархічна класифікація для підвищення точності розпізнавання захворювань.

Аналіз наукових робіт підтверджує, що використання згорткових нейронних мереж (CNN) є ефективним підходом до автоматизованої діагностики шкірних захворювань. Більшість досліджень фокусуються на класифікації меланоми, карцином, грибкових та вірусних інфекцій за допомогою різних архітектур нейромереж, зокрема MobileNet, ResNet, Inception, Xception та їх модифікацій.

Основними викликами, що залишаються нерозв'язаними, є узагальненість моделей, їхня здатність до детальної класифікації підтипів захворювань, а також необхідність пояснюваності результатів, що є критичним для клінічного застосування. Крім того, деякі роботи обмежуються аналізом однієї групи патологій (наприклад, лише грибкових чи ракових уражень), що звужує спектр застосування розроблених моделей.

Виклад основного матеріалу. У даній роботі продемонстровано результати двох моделей машинного навчання для розпізнавання шкірних захворювань на основі нейромереж. Кожна мережа призначається для певних класів хвороб, а саме для «Новоутворень шкіри» та «Вірусних захворювань». Для навчання моделі було

використано датасет DermNet, що містить зображення різних шкірних захворювань. Усього в датасеті представлено 23 класи патологій. Назва класів та розподіл для тренувальної вибірки зображено на рис. 1 для тестової на рис. 2. Оскільки розміри зображень у наборі даних були різними, для забезпечення узгодженості вхідних даних усі зображення були приведені до розміру 255×255 пікселів.

Перед початком роботи було проведено аналіз зображень на основі попередніх досліджень [7], що дозволило визначити основні особливості візуальних ознак шкірних патологій. Це дало змогу адаптувати підхід до підготовки даних і розробки архітектури моделі, а також підтвердити доцільність використання методу ієрархічної класифікації.




Рис. 1. Розподіл для тренувальної вибірки




Рис. 2. Розподіл для тестової вибірки

Однак початковий розподіл класів виявився надмірно деталізованим, що могло знижувати точність класифікації через високу внутрішньокласову варіативність. Після консультацій із практикуючим дерматологом було прийнято рішення перегрупувати класи, об'єднавши їх у більш узагальнені категорії з відповідними підкласами.

Таким чином, у рамках цього дослідження було сформовано дві основні групи захворювань які зображені в табл. 1.

Таблиця 1

Класи хвороб для навчання

Новоутворення шкіри	Вірусні захворювання
Actinic Keratosis, Basal Cell Carcinoma та інші злоякісні утворення	Herpes, HPV та інші інфекції, що передаються статевим шляхом
Melanoma, Nevi та Moles	Бородавки, молюски та інші вірусні ураження
Vascular Tumors	
Seborrheic Keratoses та інші доброякісні пухлини	

Такий підхід до структурування даних дозволяє підвищити ефективність класифікації, оскільки модель спочатку визначає основну категорію захворювання, а потім уточнює діагноз на рівні підтипу.

Далі розглянемо математичний апарат для моделі, котра розпізнаватиме клас хвороб під назвою «Новоутворення шкіри». У даній роботі використовується попередня обробка зображень за допомогою сегментації, що покращує якість вхідних даних. Сегментація виконується через метод порогового перетворення Otsu та знаходження контурів [8]:

$$T = \arg \min_{\tau} (\omega_1(\tau) \sigma_1^2(\tau) + \omega_2(\tau) \sigma_2^2(\tau)) \quad (1)$$

де:

- T – поріг, що мінімізує внутрішньокласову дисперсію σ^2 ;
- ω – ймовірність належності пікселів до класу.

Далі отримана бінарна маска накладається на вихідне зображення [9]:

$$I_{seg} = I \cdot M \quad (2)$$

де:

- I_{seg} – сегментоване зображення;
- I – оригінальне зображення;
- M – маска.

Запропонована модель згорткової нейронної мережі (CNN) має глибоку багаторівневу структуру [10]:

$$F = f(W \cdot X + b) \quad (3)$$

де:

- W – ваги фільтрів;
- X – вхідне зображення;
- b – зміщення, f – функція активації (ReLU).

Кожен шар виконує операції згортки, нормалізації та об'єднання [11]:

$$O_{i,j} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} K_{m,n} I_{i-m,j-n} \quad (4)$$

де:

- $O_{i,j}$ – вихідний піксель;
- $K_{m,n}$ – ядро згортки розміром $M \times N$.

Фінальні шари включають пов'язані шари [12]:

$$y = \sigma(W_x + b) \quad (5)$$

де:

- $\sigma(x) = \frac{e^x}{\sum e^x}$ – функція Softmax для класифікації.

Модель оптимізується за допомогою Adam-оптимізатора [13]:

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) q_t, \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) q_t^2, \end{aligned} \quad (6)$$

$$m_t = \frac{m_t}{1 - \beta_1^t}, \quad v_t = \frac{v_t}{1 - \beta_2^t},$$

$$\theta_t = \theta_{t-1} - \frac{\eta}{\sqrt{v_t + \epsilon}} m_t$$

де:

- θ – параметри моделі;
- q_t – градієнт функції втрат;
- η – швидкість навчання.

Запропонований підхід дозволяє підвищити точність класифікації завдяки попередній обробці даних та покращенню архітектури нейронної мережі.

У цьому підході використовується покращена згорткова нейронна мережа (CNN) для класифікації «Вірусних захворювань» шкіри, зокрема Herpes, HPV, Warts та Molluscum. Попередня обробка зображень включає розширену сегментацію, яка відрізняється від попередньої моделі тим, що застосовує метод покращення контрасту CLAHE (Contrast Limited Adaptive Histogram Equalization). Це дозволяє усунути нерівномірне освітлення та підкреслити уражені ділянки шкіри [14]. Для кожного пікселя зображення контраст покращується за допомогою формули:

$$C_{i,j} = \frac{H(I_{i,j}) - \min(H)}{\max(H) - \min(H)} \times 255 \quad (7)$$

де:

- $C_{i,j}$ – значення пікселя після покращення контрасту;
- $H(I_{i,j})$ – значення гістограми, а $\min(H)$ та $\max(H)$ – мінімальне та максимальне значення гістограми відповідно.

Архітектура мережі базується на чотиришаровій структурі згорткових шарів (Conv2D), кожен з яких супроводжується нормалізацією (BatchNormalization) та операціями субдискретизації (MaxPooling2D). Важливою відмінністю цієї моделі є застосування Global Average Pooling (GAP) замість традиційного Flatten-шару, що значно зменшує кількість параметрів і підвищує стійкість мережі [15]. Вихідний розмір після згортки визначається за рівнянням:

$$O = \frac{I - F + 2P}{S} + 1 \quad (8)$$

де:

- O – вихідний розмір карти ознак;
- I – розмір вхідного зображення;
- F – розмір фільтра;
- P – паддінг;
- S – крок згортки.

Фінальна частина архітектури включає щільний (Dense) шар із 256 нейронами, що відповідає за узагальнення отриманих ознак, а також Dropout (0.5) для запобігання перенаванчання. Завершується модель Softmax-класифікатором, який розподіляє ймовірності між двома класами захворювань [16]:

$$P(y_i) = \frac{e^{z_i}}{\sum_j e^{z_j}} \quad (9)$$

де:

- $P(y_i)$ – ймовірність приналежності до класу i , а;
- z_i – активація перед Softmax.

Дана модель продемонструвала високу точність класифікації та перевершила MobileNetV2 і ResNet 50, що підтверджує ефективність використання покращеної сегментації, оптимізації мережевої архітектури та адаптивних методів навчання.

Результати дослідження. Розглянемо результати для класу «Новоутворення шкіри». Графік точності на рис. 3 демонструє поступове покращення точності як на навчальному, так і на валідаційному наборах даних. Жовта лінія, що відповідає тренувальній точності, починається приблизно з 70% і зростає до 86% до четвертої епохи, що вказує на ефективне навчання моделі. Валідаційна точність, представлена червоною лінією, також збільшується, хоча з дещо меншою швидкістю, досягаючи значення, наближеного до тренувальної кривої. Такий тренд свідчить про те, що модель добре навчається та не демонструє явного перенаванчання. Більш точні результати по метрикам зображені в табл. 2.




Рис. 3. Графік точності моделі

Таблиця 2

Результати якості мережі для кожного підкласу

Клас	Precision	Recall	F1-score
Actinic Keratosis Basal Cell Carcinoma and other Malignant Lesions	0.89	0.93	0.91
Melanoma Skin Cancer Nevi and Moles	0.90	0.88	0.89
Vascular Tumors	0.88	0.89	0.89
Seborrheic Keratoses and other Benign Tumors	0.94	0.92	0.93

Матриця помилок (рис. 4) демонструє високу точність класифікації між чотирма класами: C1 (Actinic Keratosis Basal Cell Carcinoma and other Malignant Lesions), C2 (Melanoma Skin Cancer Nevi and Moles), C3 (Vascular Tumors) та C4 (Seborrheic Keratoses and other Benign Tumors). Найкраще модель класифікує C1 (50 правильних передбачень), C3 (48) та C4 (47), тоді як C2 має 45 правильних передбачень із незначним змішуванням із C1 та C3. Основні помилки спостерігаються між Melanoma Skin Cancer Nevi and Moles (C2) та Vascular Tumors (C3), що може бути наслідком схожих візуальних характеристик. Загалом модель демонструє стабільні результати, але потребує подальшої оптимізації для кращого розрізнення меланоми та судинних утворень.




Рис. 4. Матриця помилок для «Новоутворень шкіри»

Наступні результати одержані для класу «Вірусні захворювання». Щодо графіка на рис. 5, він демонструє процес зниження функції втрат для тренувальної та валідаційної вибірок протягом 20 епох. Обидві криві стабільно знижуються

без значних коливань, що вказує на ефективний процес навчання та відсутність явного перенавчання.



Рис. 5. Графік точності моделі

Матриця помилок (рис. 6) відображає ефективність класифікації між двома класами: Herpes HPV and other STDs Photos та Warts Molluscum and other Viral Infections. Правильна класифікація для першого класу становить 45 випадків, з 5 хибнокласифікованими як Warts Molluscum and other Viral Infections. Для другого класу модель правильно передбачила 44 випадки, тоді як 6 зразків були помилково віднесені до Herpes HPV and other STDs Photos. Більш точні результати по метрикам зображені в табл. 3.

Таблиця 3

Результати якості нейронної мережі для кожного підкласу

Клас	Precision	Recall	F1-core
Herpes HPV and other STDs Photos	0.88	0.90	0.89
Warts Molluscum and other Viral Infections	0.90	0.88	0.89

Отримані результати свідчать про збалансовану продуктивність моделі для обох класів, що підтверджується високими значеннями Precision та Recall. Незначна кількість помилкових класифікацій вказує на можливості подальшого покращення, наприклад, шляхом використання більшого обсягу навчальних даних або методів аугментації.

Висновки. У ході дослідження було розглянуто автоматизоване розпізнавання шкірних захворювань за допомогою згорткових нейронних мереж. Основна увага була приділена двом класам: новоутворенням шкіри (Actinic Keratosis, Basal Cell Carcinoma, Melanoma, Vascular Tumors та інші) і вірусним захворюванням (Herpes,

HPV, Warts, Molluscum та інші вірусні інфекції). Попередня обробка включала аналіз зображень та їх сегментацію, що дозволило покращити якість вхідних даних для навчання нейромережі. Було прийнято рішення об'єднати деякі класи в підгрупи для підвищення ефективності моделі, що було підтверджено консультаціями з дерматологами.




Рис. 6. Матриця помилок для «Вірусних захворювань»

Досліджено архітектуру згорткових нейронних мереж для двох основних завдань: класифікації новоутворень і вірусних захворювань. В процесі навчання були застосовані методи покращення контрасту, адаптивна сегментація та нормалізація зображень. Для оцінки продуктивності моделі використовувались метрики Precision, Recall, F1-score, а також матриці помилок, що продемонстрували високий рівень класифікації.

Результати навчання показали, що модель досягла точності 91% при класифікації новоутворень та 88–90% при класифікації вірусних захворювань, що перевершує попередні підходи. Аналіз кривих втрат і точності підтвердив стабільний процес навчання без явного перенавчання. Незважаючи на високу якість передбачень, залишаються виклики у розмежуванні схожих патологій, зокрема Melanoma та Vascular Tumors, а також Herpes та Warts Molluscum.

У перспективі планується продовження роботи над класифікацією шкірних захворювань для інших класів, зокрема розширення аналізу на рідкісні патології та комбіновані ураження. Подальші дослідження будуть спрямовані на покращення розрізнення схожих захворювань, використання більш складних архітектур нейронних мереж та застосування ієрархічного підходу до класифікації для досягнення ще вищої точності діагностики.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ:

1. R. Sadik, A. Majumder, A. A. Biswas, B. Ahammad, and M. M. Rahman, "An in-depth analysis of Convolutional Neural Network architectures with transfer learning for skin disease diagnosis," *Healthcare Analytics*, vol. 3, 2023, doi: 10.1016/j.health.2023.100143.
 2. S. Karthikeyan, A. Kingsly Jabakumar, B. Anuradha, "Studies on Different CNN Algorithms for Face Skin Disease Classification Based on Clinical Image," *Proceeding International Conference on Science and Engineering*, vol. 11, no. 1, 2023, doi: 10.52783/cienceng.v11i1.88.
 3. F. D. Wibowo, I. Palupi, and B. A. Wahyudi, "Image Detection for Common Human Skin Diseases in Indonesia Using CNN and Ensemble Learning Method," *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, 2022, doi: 10.47065/josyc.v3i4.2151.
 4. S. Ahmed *et al.*, "Human Skin Diseases Detection and Classification using CNN," in *3rd International Conference on Electrical, Computer and Communication Engineering, ECCE 2023*, 2023. doi: 10.1109/ECCE57851.2023.10101636.
 5. A. Esteva *et al.*, "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, 2017, doi: 10.1038/nature21056.
 6. B. Durgabhavani, B. Chandana, Sandhyarani, G. Lavanya, G. Srikanth, and N. Bhaskar, "Classification of Skin Disease using CNN," in *2023 International Conference on Evolutionary Algorithms and Soft Computing Techniques, EASCT 2023*, 2023. doi: 10.1109/EASCT59475.2023.10393477.
 7. E. Kinshakov and Y. Parfenenko, "Application of Machine Learning Techniques to Solve the Problem of Skin Diseases Diagnosis," in *Studies in Systems, Decision and Control*, vol. 496, Springer Science and Business Media Deutschland GmbH, 2023, pp. 101–116. doi: 10.1007/978-3-031-40997-4_7.
 8. A. M. A. Talab, Z. Huang, F. Xi, and L. Haiming, "Detection crack in image using Otsu method and multiple filtering in image processing techniques," *Optik (Stuttg)*, vol. 127, no. 3, 2016, doi: 10.1016/j.ijleo.2015.09.147.
 9. M. Kazemimoghadam, Z. Yang, M. Chen, L. Ma, W. Lu, and X. Gu, "Leveraging global binary masks for structure segmentation in medical images," *Phys Med Biol*, vol. 68, no. 18, 2023, doi: 10.1088/1361-6560/acf2e2.
 10. V. A. Ashwath, O. K. Sikha, and R. Benitez, "TS-CNN: A Three-Tier Self-Interpretable CNN for Multi-Region Medical Image Classification," *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3299850.
 11. M. Frid-Adar, I. Diamant, E. Klang, M. Amitai, J. Goldberger, and H. Greenspan, "GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification," *Neurocomputing*, vol. 321, 2018, doi: 10.1016/j.neucom.2018.09.013.
 12. K. Nirmala, K. Saruladha, and K. Dekeba, "Investigations of CNN for Medical Image Analysis for Illness Prediction," *Comput Intell Neurosci*, vol. 2022, 2022, doi: 10.1155/2022/7968200.
 13. L. Nanni, A. Manfè, G. Maguolo, A. Lumini, and S. Brahmam, "High performing ensemble of convolutional neural networks for insect pest image detection," *Ecol Inform*, vol. 67, 2022, doi: 10.1016/j.ecoinf.2021.101515.
 14. U. Kuran and E. C. Kuran, "Parameter selection for CLAHE using multi-objective cuckoo search algorithm for image contrast enhancement," *Intelligent Systems with Applications*, vol. 12, 2021, doi: 10.1016/j.iswa.2021.200051.
 15. Y. Patel *et al.*, "An Improved Dense CNN Architecture for Deepfake Image Detection," *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3251417.
 16. G. Cheng *et al.*, "Prototype-CNN for Few-Shot Object Detection in Remote Sensing Images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, 2022, doi: 10.1109/TGRS.2021.3078507.
-

REFERENCES:

1. R. Sadik, A. Majumder, A. A. Biswas, B. Ahammad, and M. M. Rahman, "An in-depth analysis of Convolutional Neural Network architectures with transfer learning for skin disease diagnosis," *Healthcare Analytics*, vol. 3, 2023, doi: 10.1016/j.health.2023.100143.
2. S. Karthikeyan, A. Kingsly Jabakumar, B. Anuradha, "Studies on Different CNN Algorithms for Face Skin Disease Classification Based on Clinical Image," *Proceeding International Conference on Science and Engineering*, vol. 11, no. 1, 2023, doi: 10.52783/cienceng.v11i1.88.
3. F. D. Wibowo, I. Palupi, and B. A. Wahyudi, "Image Detection for Common Human Skin Diseases in Indonesia Using CNN and Ensemble Learning Method," *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, 2022, doi: 10.47065/josyc.v3i4.2151.
4. S. Ahmed *et al.*, "Human Skin Diseases Detection and Classification using CNN," in *3rd International Conference on Electrical, Computer and Communication Engineering, ECCE 2023*, 2023. doi: 10.1109/ECCE57851.2023.10101636.
5. A. Esteva *et al.*, "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, 2017, doi: 10.1038/nature21056.
6. B. Durgabhavani, B. Chandana, Sandhyarani, G. Lavanya, G. Srikanth, and N. Bhaskar, "Classification of Skin Disease using CNN," in *2023 International Conference on Evolutionary Algorithms and Soft Computing Techniques, EASCT 2023*, 2023. doi: 10.1109/EASCT59475.2023.10393477.
7. E. Kinshakov and Y. Parfenenko, "Application of Machine Learning Techniques to Solve the Problem of Skin Diseases Diagnosis," in *Studies in Systems, Decision and Control*, vol. 496, Springer Science and Business Media Deutschland GmbH, 2023, pp. 101–116. doi: 10.1007/978-3-031-40997-4_7.
8. A. M. A. Talab, Z. Huang, F. Xi, and L. Haiming, "Detection crack in image using Otsu method and multiple filtering in image processing techniques," *Optik (Stuttg)*, vol. 127, no. 3, 2016, doi: 10.1016/j.ijleo.2015.09.147.
9. M. Kazemimoghadam, Z. Yang, M. Chen, L. Ma, W. Lu, and X. Gu, "Leveraging global binary masks for structure segmentation in medical images," *Phys Med Biol*, vol. 68, no. 18, 2023, doi: 10.1088/1361-6560/acf2e2.
10. V. A. Ashwath, O. K. Sikha, and R. Benitez, "TS-CNN: A Three-Tier Self-Interpretable CNN for Multi-Region Medical Image Classification," *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3299850.
11. M. Frid-Adar, I. Diamant, E. Klang, M. Amitai, J. Goldberger, and H. Greenspan, "GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification," *Neurocomputing*, vol. 321, 2018, doi: 10.1016/j.neucom.2018.09.013.
12. K. Nirmala, K. Saruladha, and K. Dekeba, "Investigations of CNN for Medical Image Analysis for Illness Prediction," *Comput Intell Neurosci*, vol. 2022, 2022, doi: 10.1155/2022/7968200.
13. L. Nanni, A. Manfè, G. Maguolo, A. Lumini, and S. Brahmam, "High performing ensemble of convolutional neural networks for insect pest image detection," *Ecol Inform*, vol. 67, 2022, doi: 10.1016/j.ecoinf.2021.101515.
14. U. Kuran and E. C. Kuran, "Parameter selection for CLAHE using multi-objective cuckoo search algorithm for image contrast enhancement," *Intelligent Systems with Applications*, vol. 12, 2021, doi: 10.1016/j.iswa.2021.200051.
15. Y. Patel *et al.*, "An Improved Dense CNN Architecture for Deepfake Image Detection," *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2023.3251417.
16. G. Cheng *et al.*, "Prototype-CNN for Few-Shot Object Detection in Remote Sensing Images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, 2022, doi: 10.1109/TGRS.2021.3078507.